

〈研究ノート〉

## 人工知能を活用した価格管理に関する研究

三 沢 英 貴・車 戸 建 謙

Hidetaka MISAWA, Takenori KURUMADO :  
A Study on the Price Control Using Artificial Intelligence

鳥取看護大学・鳥取短期大学研究紀要 第77号 抜刷

2018年7月

〈研究ノート〉

## 人工知能を活用した価格管理に関する研究

三 沢 英 貴<sup>1</sup>・車 戸 建 謙<sup>2</sup>

Hidetaka MISAWA, Takenori KURUMADO :

A Study on the Price Control Using Artificial Intelligence

通信販売における商品の販売および買取価格は種々の要因によって日々変動する。これに対応する価格管理の業務は重要業務であるが、その業務負荷や適性から担当者の育成および増員が極めて難しい。そこで本稿では、人工知能を活用した価格管理について提案する。担当者の判断を学習データとし、ニューラルネットワークを適用したモデルを実際の業務へ適用、2ヵ月間の売り上げと利益率について追跡調査を行った。

キーワード：人工知能 機械学習 ニューラルネットワーク 価格管理

### 1. 緒言

1956年のダートマス会議において命名された人工知能は2012年を境に大きな進展を見せている<sup>1)</sup>。現在の人工知能ブームは第3次ブームと位置付けられており、1995年頃から2000年にかけて爆発的に浸透したインターネットが重要な役割を果たしている。インターネットは、それまでのシステム（ローカルな取引やコミュニケーション）とは異なり、企業間や企業と一般消費者間のみではなく一般消費者間の取引や情報交換が活発となったため、取り扱うデータ量が爆発的に増加する結果となった<sup>2)</sup>。人工知能のベースには、機械学習という考え方が存在し、一般的にはデータ量が多ければ多いほどその学習効果が増加する。このような状況から現在の人工知能ブームが引き起こされたと考えられる。顧客の動向を膨大な統計データとして有している会社が、そのデータを人工知能の学習用データとして利

用しないことは考えにくい。近年の産業界における人工知能の活用は、自然な流れと言えるだろう。

著者らの一人は、通信販売を主な形態とする会社を経営しており、常時400種類以上の商品の販売および買取を行っている。商品需要や商品供給（商品の買取価格や量）の増減、競合他社の価格などが要因となり、商品の価格は毎日変動している。そのため、商品の販売および買取価格は数時間おきに価格管理の担当者によって適切な価格へ調整される。価格管理の業務は重要な業務であるが、その業務負荷（業務量や時間）は重く、また熟練や価格観と呼ばれるセンスも必要となるため、担当者の育成や増員についても極めて困難である。そこで、本稿では人工知能（AI：Artificial Intelligence）を活用した価格管理について当社内における実践例を報告する。

### 2. 現在の人工知能

#### (1) 人工知能のレベル

現在の人工知能は、『強い人工知能』と『弱い人工知能』に区別される。『強い人工知能』とは、人間が一切の教育をしなくとも自ら学び、判断し、行

1 鳥取短期大学生生活学科

2 株式会社マツプシ

動するような人工知能を意味する。つまり、人間と同等またはそれ以上の知能を持つ機械である。一方で『弱い人工知能』とは、人間の代わりに様々な処理をする人工知能を意味する。つまり、定められた専用アルゴリズムにしたがって高速に処理を実施するための機械である。現在の人工知能は、全て『弱い人工知能』であり、『強い人工知能』を実現することは不可能であると考えられている<sup>3),4)</sup>。本稿における人工知能についても『弱い人工知能』に属す。

## (2) 機械学習

人工知能のベースである機械学習 (Machine Learning) には、いくつかの種類が存在する<sup>5)~7)</sup>。

第1は教師付き学習 (Supervised Learning) と呼ばれ、入力データと出力データを用いてその特徴点を学習させる考え方である。例えば、ある動物 (馬) の画像を与え、その特徴点を学習させることを膨大に繰り返すことで、異なる馬の画像であっても馬であるとの判断が可能となる確率が上昇する。第2は教師なし学習 (Unsupervised Learning) と呼ばれ、教師付き学習が入力 (馬の画像) と出力 (これは馬である) の1対1の関係性を学習用データとすることに対して膨大な入力データのみが与えられ、正解となる出力データは与えられない。例えば、顧客の購買情報を入力データとして与え、顧客のクラスを分類するような処理に用いることが可能である。教師なし学習の場合は、正解となる顧客のクラスが出力として与えられておらず、入力データの特徴点から類似性の近いクラスに分類しているのみである。

第3は、強化学習 (Reinforcement Learning) と呼ばれ、与えられた環境における報酬が最大となるような行動 (処理) を学習させる考え方である。例えば、あるゲームを学習させる場合、ゲームに勝利することが最大の目的であるため、勝利した時点で最大の報酬が得られるアルゴリズムを考える。教師付き学習では、勝利するまでの一連の各行動に正解が与えられているが、強化学習ではそうではない。つまり、複数の行動を繰り返した結果、得られる報酬

の値 (厳密には期待値) によって逐次的に行動を評価し続けるアルゴリズムであると言える。

## (3) ニューラルネットワーク

ニューラルネットワーク (Neural Network) とは、人間の脳内にある神経回路網 (ニューロンの繋がり) を人工ニューロンという数学的モデルで表現したものであり、人工知能における代表的な手法である<sup>8)</sup>。ニューラルネットワークは、入力層、中間層、出力層と呼ばれる3種類の層から構成されており、各層の間には繋がり (ニューロンの繋がり) の強さを表現する重みが設定されている。例えば、入力が1つの場合のニューロンモデル (図1) は式 (1) で表現される。また、複数入力の場合のニューロンモデル (図2) は、式 (2) で表現される。ここで  $b$  は、出力結果の精度を向上させるためのパラメータである。つまり、外部からの入力を入力層にて確認、中間層にて重みを活用しつつ、入力の細分化や特徴抽出を実施後、出力層にて結果を返すアルゴリズムである。入力層と出力層の間に中間層が組み込まれたことによって複雑なモデルに対応、中間層の数を増やすことでさらに複雑なモデルを扱うことも可能である。本稿にて扱う手法もニューラルネットワークであり、近年、注目されている深層学習 (Deep Learning) もニューラルネットワークの中間層を

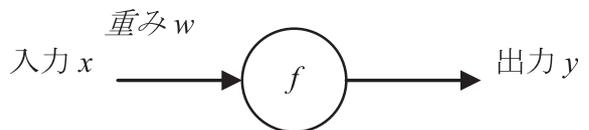


図1 ニューロンモデル (入力1つ)

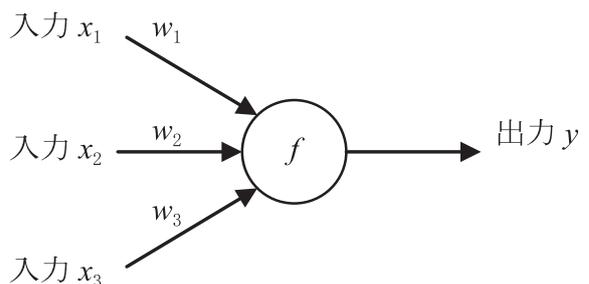


図2 ニューロンモデル (複数入力)

拡張した手法である。

$$y = f(w x + b) \quad \text{式 (1)}$$

$$y = f(w_1 x_1 + w_2 x_2 + w_3 x_3 + b) \quad \text{式 (2)}$$

### 3. モデルの概要

本章では、人工知能を活用した価格管理におけるモデルについて述べる。人工知能を価格管理に活用する場合、人工知能が適正値と大きく異なる結果を出力した場合のリスクを考慮する必要がある。買取価格については、社内システム内におけるヒューマンエラー防止機能からそのリスクが小さいため、本稿では買取価格の管理に焦点を絞る。

価格管理の担当者は、①現在の状況を確認、②価格調整の方向性（値上げと値下げ）の判断、③価格の決定というプロセス（3段階のStep）を持って最終的な価格を決定している。そこで、人工知能にも同様のプロセスを適用し、その精度を検証した後に実用性を判断した（図3）。Step1では、価格管理の担当者が実際の業務において処理を行った状況（商品毎の在庫状況、販売価格、現在の買取価格、当該商品の販売件数と買取件数（直近12時間））と結果（調整後の買取価格）を学習用データとして活用する。Step2では、価格調整の方向性について学習さ

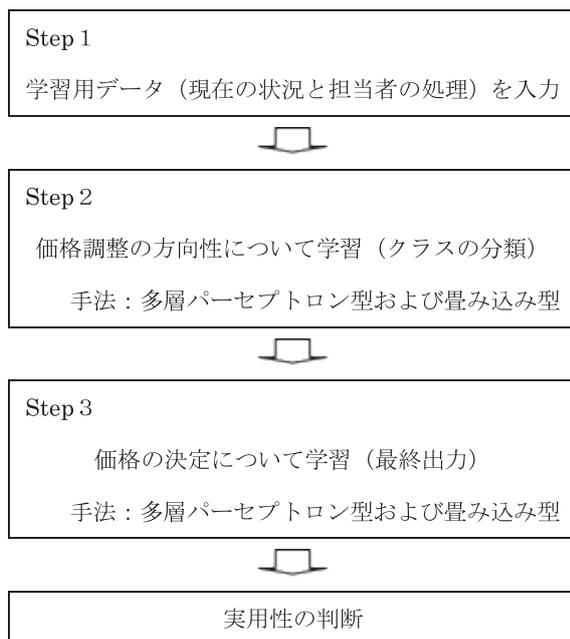


図3 人工知能による価格管理モデル

せた後にクラスの分類の精度を検証する。Step3では、Step2の結果から学習用データを価格調整のクラス毎（値上げと値下げ）に分類、それぞれについて学習させた後、その精度を検証した。また、Step2およびStep3では、代表的な2種類のニューラルネットワーク（多層パーセプトロン型と畳み込み型）を適用した<sup>9),10)</sup>。

### 4. 数値検証

#### (1) 開発環境および設定

検証に利用した開発環境を表1へ、各ニューラルネットワークの設定と共通設定を表2～表4へ示す。また、ニューラルネットワーク処理、GPUアクセラレーション開発、最適化のライブラリとしてChainer2.0.2、CUDA8.0、cuDNN5.1を利用した<sup>11),12)</sup>。各ニューラルネットワークの精度に関する評価については、学習用

表1 開発環境

|      |                                 |
|------|---------------------------------|
| スペック | g2.2xlarge (EC2) <sup>13)</sup> |
| OS   | Ubuntu16.04.2                   |
| 開発言語 | Python2.7.12                    |

表2 多層パーセプトロン型の設定

|          |          |
|----------|----------|
| 中間層      | 全2層（全結合） |
| 人工ニューロン数 | 150 ノード  |
| 学習回数     | 50,000   |

表3 畳み込み型の設定

|               |                                    |
|---------------|------------------------------------|
| 中間層数          | 全9層<br>第1層～第7層 畳み込み<br>第8層～第9層 全結合 |
| 人工ニューロン数      | 畳み込み型 60 ノード<br>全結合型 360 ノード       |
| size と stride | 各1                                 |
| padding       | ゼロパディング                            |
| Pooling層      | 無し                                 |
| 学習回数          | 10,000                             |

表4 ニューラルネットワーク共通設定

|             |              |
|-------------|--------------|
| 学習種別        | 教師付き         |
| 活性化関数       | sigmoid/Relu |
| 最適化アルゴリズム   | Adam         |
| Weight の初期値 | ランダム         |
| Bias の初期値   | ランダム         |
| 学習用データ数     | 10,756       |

データと同様の方針で作成した検証用テスト問題 100 問を用いて行った。

(2) クラスの分類に対する検証結果

クラス分類に対して2種類のニューラルネットワークを用いた検証を行った結果を表5、表6に示す。最適化アルゴリズムである Adam のパラメータは、アルゴリズムの提案者による推奨値としている<sup>14)</sup>。また、Dropout 処理（学習用データに含まれる特徴を学習しすぎること未知の問題に対する正答率が低下する過学習を緩和し、学習の精度を高める処理）についてはその有無についても比較を行った。表5と表6から畳み込み型の正解率が高く、中でも Relu 関数（Dropout あり）が高精度であった。最

表5 多層パーセプトロン型の結果

| 活性化関数   | Dropout (率) | 学習時間 (秒) | 正解率 (%) |
|---------|-------------|----------|---------|
| sigmoid | なし          | 255      | 87      |
|         | あり (0.5)    | 294      | 85      |
| Relu    | なし          | 202      | 89      |
|         | あり (0.5)    | 238      | 84      |

表6 畳み込み型の結果

| 活性化関数   | Dropout (率) | 学習時間 (秒) | 正解率 (%) |
|---------|-------------|----------|---------|
| sigmoid | なし          | 2,795    | 85      |
|         | あり (0.5)    | 2,809    | 92      |
| Relu    | なし          | 2,570    | 90      |
|         | あり (0.5)    | 2,590    | 94      |

高精度の値は94%であったが、価格管理の担当者の処理においても画一的な価格調整でない方がよいという経験から本来は値上げるべき部分を値下げたり、その逆の処理を行っている場合があるため、実用レベルの精度であると判断可能である。学習時間に関しては、多層パーセプトロン型に軍配があがっている。しかしながら、中間層数の増加とともに学習時間が増加していくことは当然の結果であり、現在の開発環境においては、畳み込み型の計算時間であっても実用レベルである。

(3) 価格の決定に対する検証結果

学習用データセットを値上げ時と値下げ時に分類して学習を実施、2種類のニューラルネットワークを用いた検証を行った結果を表7～表10に示す。また、最適化アルゴリズムとそのパラメータについては前節同様である。表7～表10より値上げ時と値下げ時のいずれにおいても多層パーセプトロン型（Relu 関数、Dropout あり）が優れた精度を示した。価格管理の業務を人工知能に置き換える場合、当然ではあるが価格の算出精度が重要となってくる。そういった面において、十分な実用精度であると考え

表7 多層パーセプトロン型の結果（値上げ時）

| 活性化関数   | Dropout (率) | 学習時間 (秒) | 総価格誤差(円) |
|---------|-------------|----------|----------|
| sigmoid | なし          | 143      | -13      |
|         | あり (0.5)    | 145      | 12       |
| Relu    | なし          | 126      | -32      |
|         | あり (0.5)    | 141      | 8        |

表8 多層パーセプトロン型の結果（値下げ時）

| 活性化関数   | Dropout (率) | 学習時間 (秒) | 総価格誤差(円) |
|---------|-------------|----------|----------|
| sigmoid | なし          | 133      | -18      |
|         | あり (0.5)    | 138      | -121     |
| Relu    | なし          | 120      | -34      |
|         | あり (0.5)    | 140      | -11      |

表9 畳み込み型の結果（値上げ時）

| 活性化関数   | Dropout (率) | 学習時間 (秒) | 総価格誤差(円) |
|---------|-------------|----------|----------|
| sigmoid | なし          | 1271     | -45      |
|         | あり (0.5)    | 1262     | -37      |
| Relu    | なし          | 1142     | -40      |
|         | あり (0.5)    | 1155     | 22       |

表10 畳み込み型の結果（値下げ時）

| 活性化関数   | Dropout (率) | 学習時間 (秒) | 総価格誤差(円) |
|---------|-------------|----------|----------|
| sigmoid | なし          | 1350     | -72      |
|         | あり (0.5)    | 1369     | -87      |
| Relu    | なし          | 1243     | -51      |
|         | あり (0.5)    | 1250     | 14       |

ことができる。

#### (4) 実際の業務における運用

最高精度のモデルを活用して実際の業務に対して人工知能による価格管理の機能を実装、運用を行った。効果の検証としては、人工知能を活用していない2ヵ月間（2017年4月，2017年5月）と人工知能を活用した2ヵ月間（2017年7月，2017年8月）の売上，買取（仕入），利率，利益の4項目について平均値を用いて比較を行った。当然，リスク管理の観点から比較的売上の少ない商品系列に対しての運用とした。また，2017年6月は，人工知能を併用しており，正確な比較が困難であるため，検証期間外としている。検証結果を表11に示す。

表11から売上は増加したが利率が低下したことが分かる。その原因としては，価格を調整する頻度

表11 実際の業務における運用結果

| AI活用 | 売上 (円)  | 買取 (円)  | 利率 (%) | 利益 (円)  |
|------|---------|---------|--------|---------|
| 未活用  | 406,581 | 305,109 | 25.0   | 101,471 |
| 活用   | 441,813 | 342,924 | 22.4   | 98,931  |

が関係していると考えられる。価格管理の業務担当者が調整を行う場合，売上の少ない商品については1日に1度程度であったが，人工知能を活用した場合は，1時間に1度から4時間に1度の調整回数にて運用を行った。運用を行う以前は，価格の調整頻度は1時間に1度程度が理想と考えていたが，担当者の時間的リソースがネックとなり，実現不可能であるとの認識であったため，人工知能を活用することで調整の頻度を増加させた検証を行った。運用の結果，利率を高めることを考えた場合，現行の調整頻度で十分であるということが言える。価格の調整頻度が増加することにより，買取価格の値上げが担当者の処理よりも早く行われる結果となり，利率が低下したと考えることができる。しかし，商品の調達についてはその分早くなったため，売上の増加に寄与していることも考えられる。

## 5. 結言

本稿では，価格管理の業務における人的コストを減少させるため，人工知能の活用を検証，その実践例を報告した。多くの場合，価格管理の業務は担当者の熟練とセンスに基づいた判断の結果，実施されていると考えられる。しかし，担当者の判断に必要な状況を数値化，学習データとして扱うことで幅広い業種において価格管理の業務が自動化できるだろう。最適な価格の調整頻度については，今後検討していく必要があるが，売上増と若干の利率低下が相殺されること，人的コストが軽減されることを考慮した場合，人工知能を活用した価格管理は一定の成果を上げたと言えるだろう。

現在，社内では提案法の適用範囲を拡大中であり，価格の調整頻度と利率の関係性を学習用データとすることで精度を維持しつつ利率を高めるモデルの可能性など，価格の調整頻度の最適化およびモデルの精度向上について継続的に検証中である。本格的な運用となった際には，担当者の業務負荷が大きく軽減される見込みである。また，販売価格の管理にお

いても学習用データのボリュームを整えることで同様の精度が期待できるため、開発および実装予定である。さらに消費者の購買行動と価格調整の関係を考慮し、マルチエージェントシミュレーションを適用した消費者の購買シミュレーションについても共同研究を検討している。

最後ではあるが、同様の課題を持つ方々の一助になれば幸いである。

#### 引用・参考文献

- 1) 『平成 28 年度版情報通信白書』, 総務省, 2016, pp. 235-240.
- 2) 本田仁「業務革新に向けた人工知能活用の考察」, 『住友化学技術誌』(2017), pp. 27-28.
- 3) 松尾豊『人工知能は人間を超えるか ディープラーニングの先にあるもの』, KADOKAWA/中経出版, 2015, pp. 48-49.
- 4) 西田豊明「人工知能スキーマ 人々は人工知能をどうとらえているか」, 『情報管理』Vol. 60, No. 1 (2017), pp. 53-54.
- 5) 馬場則夫・田中雅博 他『ソフトコンピューティングの基礎と応用』, 共立出版, 2012, pp. 5-10.
- 6) 馬場則夫・田中雅博 他『ソフトコンピューティングの基礎と応用』, 共立出版, 2012, pp. 25-29.
- 7) 三上貞義・皆川雅章 (共訳)『強化学習』, 森北出版, 2011, pp. 26-38.
- 8) 斎藤康毅『ゼロから作る Deep Learning』, オライリー・ジャパン, 2016, pp. 39-71.
- 9) 斎藤康毅『ゼロから作る Deep Learning』, オライリー・ジャパン, 2016, pp. 31-34.
- 10) 斎藤康毅『ゼロから作る Deep Learning』, オライリー・ジャパン, 2016, pp. 205-220.
- 11) Chainer オフィシャルサイト, <https://chainer.org/>(2017. 12. 28).
- 12) NVIDIA DEVELOPER, <https://developer.nvidia.com/cuda-80-ga2-download-archive>(2017. 12. 28).
- 13) Amazon Web Services, <https://aws.amazon.com/jp/>(2017. 12. 28).
- 14) Diederik P. Kingma, Jimmy Ba, “Adam: A Method for Stochastic Optimization”, Proceedings of the 3rd International Conference on Learning Representations, 2015, pp. 1-14.