

# ID-POS 分析と AI, 仮説検証に AI を どう適用し, 実践に活用するか

鈴木 聖一

従来, ID-POS 分析では統計学的手法が活用されてきたが, ここに AI の視点を入れた場合, どのような分析が可能で, 実践にどのように活用できるかを提起する. 本稿では, まず POS 分析から ID-POS 分析に至る変遷を概観し, その違いを解説する. さらに, ID-POS 分析と AI との親和性についても触れる. そして, ID-POS 分析を実践する際, 特に PDCA に AI の視点を入れた実践事例を取り上げ, 最後に展望を示す. ここで取り上げた事例を含め, ID-POS 分析に AI の視点を入れた事例はまだ少ない. 今後, 本稿のような実践事例が増え, 研究開発が進み, AI の視点が ID-POS 分析の進化につながっていくことを期待する.

キーワード: POS 分析, ID-POS 分析, PDCA, AI

## 1. ID-POS 分析は AI で進化する

### 1.1 POS 分析の変遷

POS 分析の歴史は古く, いまから約 50 年前にさかのぼる. 1974 年の 5 月にセブン-イレブンの第 1 号店が東京都江東区の豊洲にオープンし [1], コンビニエンス事業が日本で本格的にスタートした. 1978 年 8 月にはターミナルセブンによる発注が開始される. そして, 1982 年 10 月には, POS (販売時点情報管理) システムが導入され, 同時に, EOB (電子発注台帳) による発注も始まった. この頃が日本における POS 分析の黎明期といえ, いわゆる「単品管理」による POS 分析が始まった. 本稿では, 図 1 のように, 事実上, ここから始まる POS 分析の変遷を三つ, すなわち, POS 分析\_01, POS 分析\_02, POS 分析\_03 に分けて概観する. それぞれの段階で POS 分析にはターニングポイントがある. POS 分析\_01 は数量と金額での POS 分析, POS 分析\_02 はこれに客数, すなわち, レシート枚数が加わった POS 分析である. そして, POS 分析\_03 がユニーク客数, すなわち, ID が加わったいわゆる ID-POS 分析の段階である.

#### 1.1.1 POS 分析\_01: 数量と金額での POS 分析

POS 分析\_01 は POS 分析の原点ともいえ, 商品売買から得られる販売金額と販売数量のみをもとに POS 分析を行う段階である. これ以外の分析要素はなく, ここから平均単価を販売金額/販売数量で算出する. 通常 POS システムは, PLU (Price Look Up) の仕組みを使っており, あらかじめ登録しておいた商品の売価

を 13 桁の商品のバーコードをスキャンした瞬間に呼び出し, 買い物金額を集計するが, この PLU の価格は, 特売, 値下げなどで目まぐるしく変わるため POS 分析の価格として活用しにくい. そこで, POS 分析に活用する価格は分析対象期間の販売金額/販売数量で算出し, これを POS 分析に活用することが一般的である. したがって, この時点の POS 分析の主要な指標は三つ, 販売金額, 販売数量, 平均単価となる. ちなみに, POS 分析の初期の頃の単品管理は, 販売数量を ABC 分析し, C 商品, すなわち, 死筋の排除を目指した. そして, その結果として売れ筋を残し, ロスの管理と売上アップの双方を求めた POS 分析手法である.

#### 1.1.2 POS 分析\_02: 客数が加わった POS 分析

POS システムが時代とともに高度化してくると, これまでの三つの要素に新たな要素が加わる. POS 分析に影響を与える要素としては, POS システムから客数が算出できるようになったことである. 客数は今までいうユニーク客数ではなく, 買い物回数, すなわち, レシート枚数のことであるが, これを顧客と見なし, 客数として POS 分析では定着していく. 結果, ID-POS 分析が可能となった現在でも客数と ID 客数, すなわち, ユニーク客数との区別があいまいとなり, POS 分析に混乱をきたしている. 当時は, ユニーク客数を把握する技術が十分に開発されていなかったため, その後も客数が POS 分析の一般用語として定着していった. POS 分析\_02 はこの客数が加わった場合の POS 分析であり, これにより, 分析も複雑化するが, POS 分析\_01 ではできなかったさまざまな POS 分析が可能となる.

客数が加わることで, POS 分析がどう変化したかであるが, POS 分析\_01 では, 売上高 = 数量 × 平均単価

すずき しょういち

株式会社 ID プラスアイ

〒114-0023 東京都北区滝野川 5-33-3

# POS分析の変遷

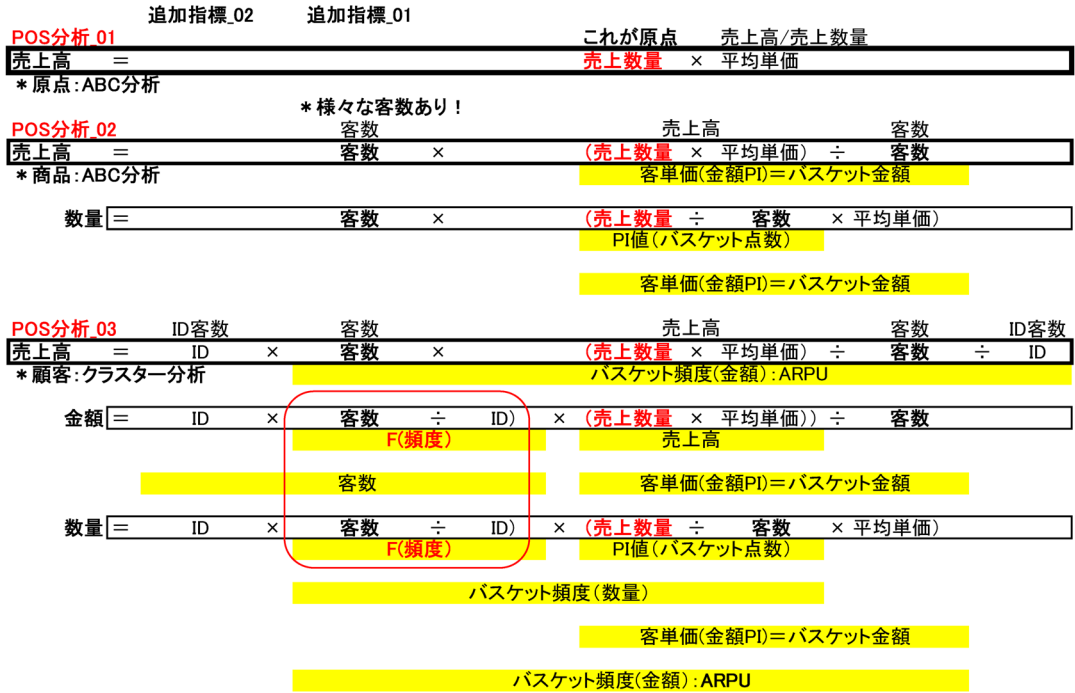


図 1 POS 分析の変遷

が基本数式であるが、これに客数が加わると以下のよう  
に売上高を分解することが可能となる。

$$\begin{aligned} \text{売上高} &= \text{客数} \times (\text{数量} \times \text{平均単価}) / \text{客数} & (1) \\ &= \text{客数} \times (\text{数量} / \text{客数}) \times \text{平均単価} & (2) \end{aligned}$$

この (1) が現在でも大半の小売業が活用する売上高 = 客数 × 客単価であり、POS 分析\_02 の基本数式の一つである。客単価は (1) から (数量 × 平均単価) / 客数のことであり、客数あたりの売上高である。そして、ここから (2) への分解が可能なることから、POS 分析\_02 は、さらに新たな指標 (数量/客数) を生む。これが小売業界に急速に普及した PI 値 (Purchase Index)[2] である。これにより、POS 分析\_02 は売上高を客数と PI 値と平均単価の 3 次元でとらえることが可能となり、さらに、(1) の客単価も PI 値 × 平均単価に分解でき、POS 分析\_02 の分析の幅を広げた。

また、このように売上高、数量を客数により、相対化できることがわかり、売上高そのものを相対化したさまざまな状況での比較分析が可能となった。たとえば、チェーンストアの各店舗の売上高をそのまま比較するのではなく、客数で割った客単価、PI 値で比較し、店舗間の規模の格差を是正する POS 分析、過去と現在を比較し、販促効果を客単価、PI 値で比較し、時間差を

是正する POS 分析などである。ちなみに、このような相対分析が可能となったことから、POS 分析\_02 はさらに発展し、客数のかわりに従業員数や売場面積を入れて POS 分析を行い、売上分析だけでなく、生産性の分析への応用にも広がっていった。

### 1.1.3 POS 分析\_03: ユニーク客数が加わった POS 分析

長らく POS 分析\_02 の時代が続き、現在でも多くの小売業が POS 分析\_02 を実践活用している。これに対して、ここ最近、にわか注目されるようになったのがユニーク客数を活用した POS 分析、すなわち、POS 分析\_03 である。これは POS システムが高度化し、商品データだけでなく、顧客データも管理できるようになったことに加え、ポイントカードの普及により顧客一人一人を識別できることが可能となり、POS 分析が ID、顧客一人一人をユニークに管理できるようになったことが大きい。特に、欧米ではユニーク客数にもとづく POS 分析が発展し、このユニーク客数による POS 分析を専門に行うダンハンビーなどの世界的なマーケティング会社が大手小売業と次々と契約していったことも、普及に拍車をかけた。また、インターネットの目覚ましい発展、携帯電話、スマートフォンの普及により、顧客一人一人に対するマーケティング

グ戦略が発展したことも大きく、POS分析はユニーク客数を起点にして、POS分析\_03の新たな段階に入ったといえる。

## 1.2 AIへの橋渡しとなるPOS分析の指標

### 1.2.1 ユニーク客数、頻度とAI

ここ数年、AIが注目され、目覚ましい成果が次々に報じられている。本稿ではAIについては、判別、推論、予測などに適用されるアルゴリズム全般と広くとらえて論じる。

AIはPOS分析の世界でも、じわじわと活用が広がりつつある。特に、POS分析\_03の段階、すなわち、ユニーク客数を組み込んだID-POS分析とAIは相性がよい。通常、AIは教師あり学習、すなわち、事前にAIに学習させる学習データが必須となるが、その学習データの作成にPOS分析が活用され始めている。POS分析\_01、02の段階では学習データを作成するうえにおいて、指標そのものが質、量ともに、十分でなかったが、POS分析\_03では指標が豊富であり、かつ、これまで算出できなかった質の高い指標を学習データに活用することが可能となった。

その一つがPOS分析\_03特有の指標、ユニーク客数と頻度である。この二つの指標は対となっており、 $客数 = \text{ユニーク客数} \times (\text{客数} / \text{ユニーク客数})$ で算出される。この客数/ユニーク客数が頻度であり、ユニーク客数なくしては算出不可能なPOS分析\_03特有の指標である。しかも、ユニーク客数で除して算出している指標であり、ユニーク客数と一体となった指標である。AIにこの指標を活用することにより、これまでのPOS分析\_01、02では分析できなかった頻度の概念を加え、AIで分析することが可能となる。結果、たとえば、AIで因果推論する場合、頻度の低いトライアル顧客の場合と頻度の高いロイヤルカスタマーなどに分けてAIに学習させることができ、その結果を頻度ごとに活用することも可能となる。POS分析\_03はその意味でAIの適用の幅を広げたともいえる。

### 1.2.2 併売とAI

POS分析\_03でもう一つAIと相性のよい指標が併売である。もともと併売はPOS分析\_02でも可能であるが、ユニーク客数を考慮していない併売であるため、顧客併売（期間併売）の算出ができなかった。したがって、AIで学習データを作成した場合、POS分析\_02では顧客ごとに学習データの作成ができず、商品ごとの学習データしか作成できなかったといえる。POS分析\_03となり、ユニーク客数が把握でき、AIの学習データは顧客、すなわち、ユニーク客ごとに作成

が可能となった。さらに、併売もユニーク客ごとに把握ができるため、期間をまたがった併売の把握が可能となり、いわゆる顧客併売が可能となった。

AI、特に、推論のAIでは、この顧客併売が必須であり、これはPOS分析\_03になってはじめて可能となる。特に、BN（Bayesian Network: ベイジアンネットワーク）は、そもそもベイズの定理をもとに成立しているためPOS分析\_03は必須といえる。ベイズの定理は結果から原因を推論できることから、従来の併売分析ではできなかった商品間の親子関係を顧客併売から導き出せ、さらに、その推論が可能となる。その意味では、POS分析\_03はAIの時代のPOS分析ともいえ、AIと相性抜群の指標を生み出したともいえる。さらに、POS分析\_03で算出された頻度が加わると、AIに併売 + 頻度を加えた学習データの作成が可能となり、より実践的なAIの適用が可能となる。POS分析\_03はAIの時代に必須のPOS分析といえ、POS分析\_03つまりID-POS分析となってPOS分析がAIと融合したといえよう。

## 1.3 AIの視点を入れたPDCA（仮説検証）サイクル構築のポイント

AIをID-POS分析に適用するポイントはID-POS分析の業務にAIをどう組み込むかである。通常、POS分析の目的は検証にあり、さらに、仮説づくりにある。いわゆる、PDCAがPOS分析そのものの目的といっても過言でない。PはPlan、仮説づくりであり、DはDo、実践であり、CはCheck、検証、そして、AはAction、改善となる。このPDCAサイクルをどうPOS分析をもとに回すかが実践そのものといえる。

このPDCAサイクルに図2のようにAIを組み込めれば、POS分析、特に、ID-POS分析とAIは融合し、相乗効果を発揮し、PDCAサイクルを効果的に、しかも、速く回すことができ、実践にAIを組み込むことが可能となる。今回、三つのAIのアルゴリズムをPDCAに組み込むとすると、どこが最適かを検討した結果、図2のそれぞれのPDCAの段階に適用することがスタートとなった。現在、この適用事例をさまざまなケースで実践しており、今後、さらに改良し、AIとPOS分析の融合をはかってゆく予定である。

ここでは三つのAIを取り上げるが、まず、PDCAのP、Planと相性の良いAIは判別、クラスタリングを得意とするPLSA（Probabilistic Latent Semantic Analysis：確率的潜在意味解析）である。POS分析の結果を学習データにし、PLSAでさまざまなクラスタリングを行い、商品視点と顧客視点の双方から従来、人

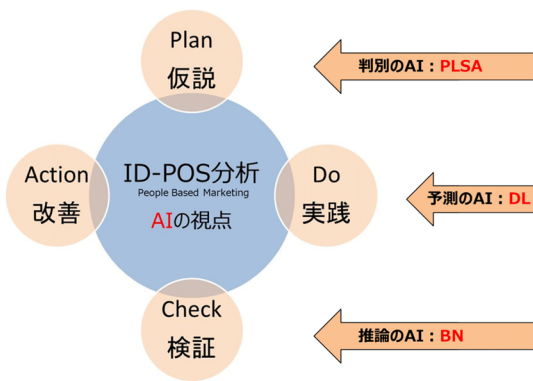


図2 ID-POS分析のPDCAとAIの視点

間の思考では思いもつかなかったさまざまな仮説を導き出すことが可能となる。次に、PDCAのD、Doと相性の良いAIはDL (Deep Learning) である。実践するには事前の結果の予測が欠かせないが、従来の統計学の回帰分析などに加え、AIを加えることで、より精度の高い予測が期待できる。そして、C、Checkと相性が良いAIがBNである。P、Dで十分な学習データができあがるので、これをBNにかけ、推論することにより、まさに、検証が可能となる。さらに、仮説以前のデータをBNにかけ、検証結果と比較すれば仮説の良し悪しの判断にも活用できる。

このようにPOS分析とAIはPDCAを通じて融合することが可能となり、これまでのID-POS分析のみでのPDCAからAIの視点を入れた、より精度の高いPDCAサイクルを作り上げることが可能となる。また、ここではPDCAのそれぞれの段階でAIの各アルゴリズムの得意とするところの適用を検討したが、AIは応用範囲が広いことから、PDCAの二つ、三つ、あるいはすべてに適用する可能性を秘め、さらに、AIを組みあわせてのハイブリッドな適用も今後考えていくべきであろう。AIとID-POS分析の融合はまだ始まったばかりといえ、今後、さまざまな可能性を追求していきたい。

## 2. AIのID-POS分析への適用事例

### 2.1 BNのID-POS分析への活用事例：推論のAI

AIをID-POS分析に適用する際には、学習データありの場合と学習データなしの場合があるが、本稿でとりあげる適用事例は、すべて学習データありの場合である。現状、AIの視点からID-POS分析がなされた事例はまだ少なく、AIが適用されないID-POS分析のみの事例は豊富である。そこで、既存のID-POS分析の結果を学習データとして再構成し、ここにAIの

視点を入れた場合、どのような結果が得られるかに注目した。

本稿では、ここ数年、AIの視点からID-POS分析に挑戦してきた中から、代表的なAIのアルゴリズムを取り上げ、分析事例を解説したい。まずは、推論のAI、BN [3] である。BNにID-POS分析を適用するには、BN特有の学習データの作成が不可欠である。特に、ID-POS分析特有のユニーク客数と頻度をどう組み込むかが要諦といえる。従来、BNはデータを0か1に離散化し、学習データを作成してきた。ID-POS分析においても、そのデータを0か1に離散化し、学習データを作成することはもちろん可能だが、ID-POS分析特有のユニーク客数と頻度をダイレクトに反映させることは一工夫必要である。また、ID-POS分析のどの場面にBNを適用するかも大きなテーマである。そこで、本稿ではID-POS分析の適用場面として棚割り分析に焦点を当てた。棚割り分析に焦点を当てた理由は、一つの棚割りを構成する商品と顧客、ここではユニーク客数であるが、BNをかける規模がうまくはまるからである。一般的な食品スーパー、ドラッグストアなどの小売業の棚割りは、商品数が約100種類ぐらいいであり、その年間購入顧客数は1店舗あたり数千人が実態である。この規模の分析であれば、BNにかけたとき、その結果を得られる時間も、その結果の視覚化も容易であり、しかも、人間が理解しやすい範囲に収まる。これが商品数千品目、顧客数百万人となると、BNで結果を得られるまでに膨大な時間がかかり、さらに、視覚化した場合、複雑になり、人間が理解しにくく、実践的ではなくなる。

ここで取り上げた図3は「水」の棚割り分析事例だが、商品は数十種類、顧客は数千人であり、BNが構造学習する時間もわずかであり、推論も容易に可能である。また、図3では因果関係図を円形、階層形にして視覚化した。一目で商品間の親子関係がわかりやすく表現できた。

このように棚割りへのAI、ここではBNへの適用は実践的であり、実務上も無理のない範囲に収まっている。ちなみに、ID-POS分析特有のユニーク客数と頻度をどこに組み入れたかであるが、学習データの商品と対になる顧客をユニーク客数として組み込み、その関係数に頻度を組み込んだ。その際、頻度を四つに分け、0頻度、1回頻度、2回頻度、3回以上の頻度として、すべての商品と顧客の関係を四つに離散化して学習データを作成し、BNにかけた。

この離散化までがID-POS分析から学習データを作



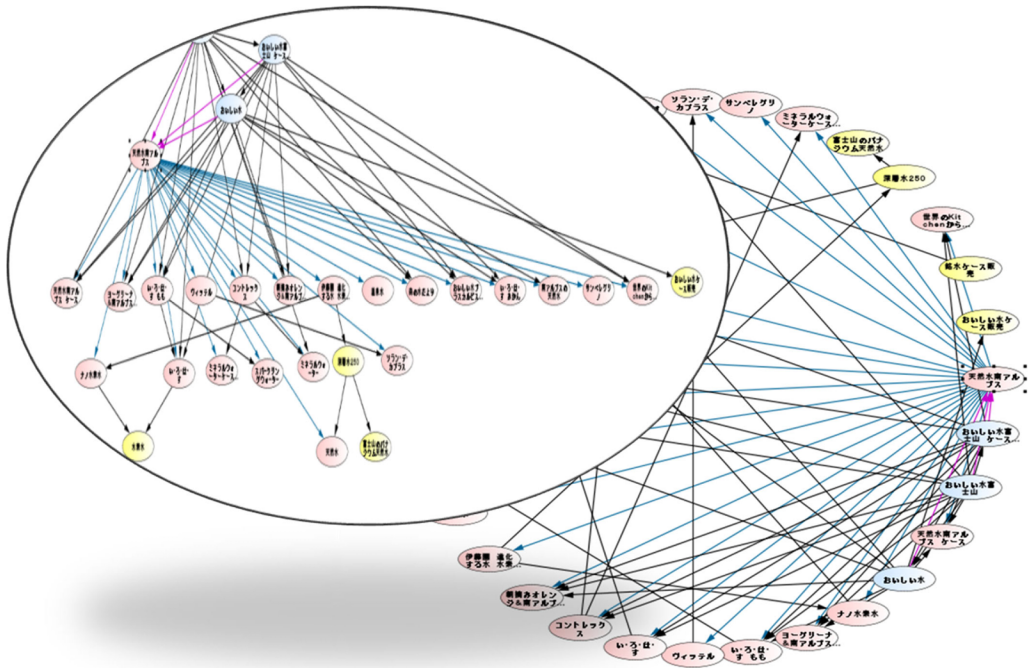


図3 ベイジアンネットワークの ID-POS 分析への活用事例

成するまでのプロセスであり、学習データから先が AI の領域となる。結果、従来、ID-POS 分析に活用していた統計学的な分析は学習データを介して、AI に置き換わることになる。そして、いったん、BN で構造学習、すなわち、モデルができあがると、ここからが AI の真骨頂、推論となる。この推論では頻度が活躍し、0 頻度推論、1 回頻度（トライアル顧客）推論、2 回頻度（リピーター）推論、3 回以上頻度（ロイヤルカスタマー）推論と分けて推論が可能となり、その結果を、ここでは水の棚割りに POS 分析では得られない、ID-POS 分析特有の独自の視点、しかも、AI での推論を入れた棚割り分析が可能となる。また、現時点の BN のアルゴリズムでは親子関係は視覚化できるが、推論を反映させた矢印の中身までは表現できないので、今後、推論結果を ID-POS 分析に返すことが、課題となろう。

以上が AI、BN を ID-POS 分析に適用する一連の流れであるが、実際、この手法を用いて実際の棚割りへの応用がさまざまなカテゴリーで進んでいる。これまでの POS 分析での棚割り分析に対して、「AI 棚割り分析」という新たな領域が開拓されつつある。これにより、これまでの POS 分析はもちろん、ID-POS 分析でも得られなかった AI 独自の視点を得られるようになり、新たな AI での棚割り、そして、棚割り後の

新たな AI での販促が確立されつつある。

## 2.2 PLSA の ID-POS 分析への活用事例：判別の AI

次に、PLSA の ID-POS 分析への適用事例であるが、もともと、この AI はクラスタリングを得意とすることから、従来、ID-POS 分析でも取り組まれていた商品 DNA（クラスタリング）、顧客 DNA（クラスタリング）への活用が期待できる。商品 DNA、顧客 DNA は ID-POS 分析では別々にクラスタリングし、そのクラスターをもとにマーチャンダイジング、マーケティング戦略を立案することに活用されてきた。その意味では小売業界では長い歴史があり、各社、独自のさまざまなクラスターをもっているのが実態である。ただ、残念ながら、ここに AI を取り入れた事例はまだわずかであり、本稿で取り上げる PLSA を活用して、ID-POS 分析を融合させたクラスタリングの事例はさらに少ない。ここでは水の事例を取り上げるが、ID-POS 分析特有のユニーク客数と頻度をもとに、商品と顧客を同時に、しかもソフトにクラスタリングしたユニークな応用事例である。PLSA [4] はもともと文章解析が目的で生まれた AI であるため、文章を単語と文節に分け、この双方を同時にソフトクラスタリングすることにより、そこから文章の意味を解析することが目的であった。この AI の技術をどう ID-POS 分析に適用するか

商品名	Z1	Z2	Z3				
	100%	100%	100%		Z1	Z2	Z3
1 南アルプスの天然水	0%	1%	0%	100%	0%	100%	0%
2 世界のKitchenから5種ベリーと天然水	0%	1%	0%	100%	0%	100%	0%
3 銘水ケース販売	0%	0%	0%	100%	0%	100%	0%
4 森の水だよりケース販売	0%	0%	0%	100%	0%	100%	0%
5 サンベレグリノ	0%	0%	0%	100%	29%	71%	0%
6 天然水南アルプス ケース	1%	4%	0%	100%	29%	67%	4%
7 おいしい水富士山 ケース販売	5%	11%	1%	100%	34%	56%	10%
8 ミネラルウォーターケース販売	0%	0%	0%	100%	0%	54%	46%
9 いろいろはす みかん	1%	2%	1%	100%	23%	46%	32%
10 おいしい水プラスカルピスの乳酸菌	2%	3%	1%	100%	32%	45%	23%

図4 PLSAのID-POS分析への活用事例。ここではPLSAにより、Z1、Z2、Z3の三つのクラスターを抽出した。左表は、各クラスターの商品の縦の構成比を示しており、右表は、各クラスターの商品の横の構成比を示している。

であるが、ID-POS分析はそもそも商品と顧客の関係を分析することが目的であるため、単語を顧客、文節を商品に置き換えての分析ができる。この時点で顧客はユニークであることが必須となるため、ID-POS分析がそのまま活用可能となる。さらに、PLSAは単語と文節を出現頻度の数値で分析することから、ID-POS分析の購入頻度をそのまま当てはめることができる。しかも、BNと違い、離散化は必ずしも必要ないので、頻度をそのままPLSAにかけることも可能である。

今回取り上げた事例では、水の購入顧客、ユニーク客数とその顧客の水の全購入商品とを頻度を用いてPLSAのアルゴリズム[5]にかけている。ここでは、三つにクラスター化した結果を提示しているが、水の購入顧客、その購入顧客が購入している水の商品、双方がきれいにソフトクラスタリングされている結果が得られた。水の一つ一つ見ると、図4のように、クラスター100%の商品もあれば、71%、67%などの商品もあり、ソフトクラスタリングされていることが読み取れる。従来のPOS分析における商品DNAで算出されるクラスター分析はハードクラスタリング、かつ、商品のみクラスタリングであったため、PLSAのような示唆に富む分析結果は得られなかった。PLSAのID-POS分析への適用は今後、さまざまな可能性を秘めており、従来のPOS分析、特にID-POS分析の進化をもたらしてゆくと期待できる。

### 2.3 DLのID-POS分析への活用事例：予測のAI

そして、三つ目のAI、DLであるが、このAIは本来、次元削減することが目的といえるが、その応用として、さまざまな説明変数から特徴量を見出し、目的変数との関係を導き、予測に応用することが可能となる。この技術を用いて、ID-POS分析に適用する際、さまざまな応用が期待できる。また、この説明変数は必ず

しも、分析データである必要はなく、画像でも映像でも可能である。本稿ではID-POS分析とAIがテーマであることから、顧客ランクの予測の事例を取り上げた。ID-POS分析で顧客をランキングする方法はさまざまであり、さまざまな工夫がみられる。ここでは顧客ランクにID-POS分析特有の頻度を用いてランキングした。まずはトライアル顧客、対象期間に1回しか購入しない顧客をZ顧客(図5のZ)とした。結果、Z顧客以外はすべてリピート顧客となるが、この内、上位10%の顧客をS顧客、下位10%の顧客をB顧客、残りのリピート顧客をA顧客と、顧客を4ランクに分けた。ちなみに、上位、下位の基準は、リピーターの平均頻度+標準偏差以上をS顧客、リピーターの平均頻度-標準偏差以下をB顧客、残りのリピート顧客をA顧客としても良い。実務的には、上下10%でも標準偏差を用いても大きな差異はないといえ、今回は簡便な方法、上下10%でランク分けを行った。

DL[6]の学習データであるが、ID-POS分析で算出可能なさまざまな説明変数を用いて作成し、さまざまなケースで試してみた。本稿の事例はその中で、バスケット関係の指標、すなわち、バスケット金額、バスケット点数、価格の三つで予測を試みたものである。その結果、64%の正解率となり、まだまだ改善の余地があるが、一定の成果が得られた。

実際に顧客ランクの予測をして見ると、図5のように、境目、すなわち、ZとB、AとB、AとS、ここが微妙にずれ、予測を外すケースが多かった。実際、ランクの境目は微妙であり、DLも迷っている様子が数多く見いだされた。これはバスケット関係の指標のみで予測を試みたことや、学習回数、中間層の数など、さまざまな要因が考えられ、これを特定することは難しく、膨大な試行錯誤が必要なが改めて確認できた。

会員番号	真偽	予測	正解	ランクS	ランクA	ランクB	ランクZ	金額PI	価格	数量PI	F(顧客)	金額	数量	バスケット頻度	F(商品)
389	FALSE	Z	B	4%	30%	27%	39%	881	881	3	6	966	4	966	4
149	FALSE	Z	B	3%	30%	27%	39%	796	796	2	4	796	2	796	2
304	FALSE	Z	B	4%	32%	27%	38%	453	453	2	4	453	2	453	2
17	FALSE	Z	B	4%	31%	27%	38%	398	398	1	2	796	2	796	2
311	FALSE	Z	B	4%	31%	26%	39%	298	298	1	2	596	2	596	2
284	FALSE	A	B	8%	44%	18%	30%	117	78	2	2	234	3	234	2
321	FALSE	A	B	8%	45%	18%	29%	128	85	2	2	255	3	255	2
481	FALSE	A	B	8%	46%	18%	28%	132	88	2	2	264	3	264	2
130	FALSE	A	B	8%	50%	20%	22%	228	153	3	4	228	3	228	2
141	FALSE	A	B	8%	50%	20%	22%	240	155	3	4	240	3	240	2
251	FALSE	A	S	8%	53%	20%	18%	669	574	4	36	2074	11	2074	9
82	FALSE	A	S	8%	53%	20%	18%	816	557	6	27	2071	22	2071	9
71	FALSE	A	S	8%	53%	20%	18%	387	298	1	10	3874	13	3874	10
497	FALSE	A	S	8%	52%	20%	19%	327	241	4	27	1619	21	1619	14
94	FALSE	A	S	8%	50%	20%	22%	192	158	2	20	1035	13	1035	10

図5 Deep Learning の ID-POS 分析への活用事例

DL での予測は、その意味であらゆる可能性を時間をかけて試行錯誤し、学習データの作成だけでなく、いわゆる、チューニングも重要な要素であり、実務に応用するには根気と時間がかかるめんどろな AI であるといえよう。

なお、今回は事例としては取り上げていないが、ID-POS 分析への応用としては、需要予測にも活用可能である。適用方法は本事例と同様、学習データを ID-POS 分析のさまざまな指標から作成することになるが、本事例と大きく違う点は需要予測に影響を与える天候情報や販売促進情報、曜日、時間など、さまざまな関連情報を学習データに組み込む点が違う。ただし、本事例でも顧客属性が把握できるのであれば年収、性別、年齢、職業、居住地域などを学習データに組み入れることもポイントである。

このように DL では ID-POS 分析と相性がよく、ID-POS 分析関連の指標に加え、予測にかかわる説明変数が把握できるのであれば、それも合わせて学習データに組み込み、AI にかけることによって、予測精度の改善が期待できる。

### 3. 今後の展望

以上、「ID-POS 分析と AI、仮説検証に AI をどう適用し、実践に活用するか」について、POS 分析の変遷をたどり、ID-POS 分析と AI との相性の良さを、特に PDCA の観点から論じ、その応用として、三つの AI、ベイジアンネットワーク、PLSA、DL の事例を取り上げた。この試みはまだ始まったばかりといえ、ID-POS 分析への AI の活用は、今後、さまざまな研究開発が取り組まれていくことになろう。

本稿でも触れたが、その際、重要な課題は学習デー

タをどう作成するかと、ID-POS 分析のどこに実践応用するかにある。ID-POS 分析は ID-POS データを分析し、何らかの結果を算出することが目的であるが、従来、その分析には統計学が用いられてきた。統計学の研究成果がそのまま ID-POS 分析に応用されてきたといえる。ただ、統計学だけで実践的に活用するには十分でない場合もある。

ID-POS 分析を実践に活用するには実践が求めている結論を算出することはもちろんであるが、現場で日々展開されている複雑な事象に対して、現場の人間が判別をし、推論を加え、予測することが求められる。この判別、推論、予測、これこそが AI の役割であるといえ、今後の ID-POS 分析の助けになる要素であるといえる。AI とは従来、自動発注などに活用される自動化の技術のように思われているが、本来、人間を助けるものであり、より精度の高い発注、低コストで高速に実施するための人間支援技術であるといえる。このように人間を支援する視点から AI を考えれば、人間がすべき判別、推論、予測を支援することが AI の本来の役割である。

実際、本稿で取り上げた PDCA、棚割りへの応用、販促への応用、商品 DNA、顧客 DNA の構築、そして、顧客ランクの予想などは、現場の人間が ID-POS 分析に膨大な時間をかけ、知恵を絞り、実践しているのが実態である。ここに AI を入れることにより、従来の統計解析だけではできなかった人間支援に寄与する可能性が高いといえよう。AI とはこのような視点で活用することがポイントであるといえ、自動化することではない。

本稿では限られた AI の事例の呈示であったが、今後、AI の技術をさらに磨き、「ID-POS 分析は AI で進

化する」をスローガンに、人間支援の技術、サービス開発に取り組んでゆきたい。まだまだ、この試みは始まったばかりといえ、まずは、ID-POS分析 with AI、そして、ゆくゆくはAI in ID-POS分析の時代を目指して研究開発を続けていく。

#### 参考文献

- [1] セブン-イレブン、沿革、<https://www.sej.co.jp/company/enkaku.html> (2020年9月29日閲覧)
- [2] 鈴木聖一、『船井総研の「客単価アップ」大革命』、明日香出版社、1995。
- [3] (株)NTT データ数理システム、BayoLinks、<https://www.msi.co.jp/bayolink/> (2020年9月29日閲覧)
- [4] T. Hofmann, “Probabilistic latent semantic analysis,” *arXiv preprint*, arXiv:1301.6705, 2013.
- [5] (株)NTT データ数理システム、Visual Mining Studio、<https://www.msi.co.jp/vmstudio/> (2020年9月29日閲覧)
- [6] (株)NTT データ数理システム、Deep Learner、<https://www.msi.co.jp/deeplearner/> (2020年9月29日閲覧)