### 原著論文

# 店舗の属性に応じた売上データの生成に関する実験

### 吉岡 佑磨\*, 髙橋 正人\*\*, 大谷 毅\*\*

\* 信州大学大学院, \*\* 信州大学

## Generation of Selling Data based on Properties of the Store

Yuma YOSHIOKA\*, Masato TAKAHASHI\*\* and Tsuyoshi OTANI\*\*

\*\* Graduate School of Science and Technology, Shinshu University, Ueda-shi, Nagano 386-8567, Japan \*\* Shinshu University, 3-15-1 Tokida, Ueda-shi, Nagano 386-8567, Japan

**Abstract:** Supposing to start new restaurant, Y, estimation of selling data of it was carried out by using the data of existing similar restaurant, X. The scenario of estimation is as follows. Project implementing body, A, have no experience to manage restaurant. Hence, A have to estimate the selling data of Y which A is going to start in near future. Therefore, A tries to estimate the selling data of Y by comparing with the existing restaurant X which is already managed by other project implementing body, B. Further, we tried to elucidate characteristics of restaurant business in comparison with other type of business, i.e. fashion apparel and mode business. In restaurant business, number of customers are restricted by the number of chairs and tables. However, fashion business doesn't have such a restriction, further number of items is huge.

**Keywords:** Store-business, Sales data, Food and beverage, Fashion, Merchandising

#### 1. テーマ

入手しがたい現実のデータを補完する意味で、人工データを生成させることに関心があるためか、人工データを論じた先行研究は多々ある[注1]. 本稿は、実務への応用に向けた問題点を検討する。同一業種の類似業態店の詳細データがあれば、ストア事業の新規出店のfeasibility study はより円滑に進む。また、チェーンオペレーションの事業者が多数の店舗(例300店舗)を類型化し、カテゴリー毎に標準値を設定し、製造業にならって「標準差異」をもって店舗をマネジメントすることも有用である[注2].

事業主体Aの新規業態 $P_j$ への進出に際し、仮想店Y店の feasibility を明らかにするため、Aがその先行事例 (事業主体Bが業態 $P_j$ により運営する実在店X) に注目した状況を想定する。AはXを観察し、Bの実在店Xの「写像」としての仮想店X'を想定する。そして、X'店の詳細データを人工的に構築し、ゆくゆくAの仮想店Yのfeasibility studyに寄与させる。本稿ではX'店のデータの生成実験を試みる。

稿者 ≒ 事業主体A…仮想·Y<sub>Pj</sub>店開業…写像·X'<sub>Pj</sub>店 † 推定 事業主体B… …実在·X<sub>Pj</sub>店

本稿は料飲事業を扱うが、その過程で、モノを扱う物販店 (ファッション衣料小売)と比較する.

料飲に比べて座席という制約はなくなるが、ファッション 衣料小売事業では、商品属性がきわめて複雑になる事情をあ きらかにし、あわせて当該事業でいうマーチャンダイジング (以下MD) をフォローし、人工データ生成の視点から、その特徴にも注目する.

## 2. B社業態 $P_i$ に関する情報

人工データの構築にあっては、事業主体Aが、Bおよび業態 $P_j$ 、実在店Xの現状を、業界水準で熟知し観察できる状態達していなければならない。

人工データ生成の立場は、①AとBを鳥瞰する立場、②Aの依頼を受けBを観察する立場がある。本稿は②を採る。

そのうえで、本ケースが扱う業種を料飲事業とし、事業主体AからみたB、業態 $P_j$ および仮想店Yについての外形的条件は既知とする。BからみたXは既知だが、AからみたXは未知である。Aが、Xの写像X を描くにしても、Xの外形的条件をある程度既知とするなど、相応の「概念装置」が不可欠である。

AはBの店舗展開の状況、献立立案・材料購買の裁量、事業所と本部ないし子会社・関係会社の状況、社内手数料、所要量把握の方法(アナログ・ERP・POS)、調理・製造工程と購買管理の関連事項[注3]について、相応の調査が進んでいるものとし、そのうえでXを観察しながら、X'の人工データを構築する。

以上のことを概括するなら、人工データの生成にあっては、相応の「シナリオ」が必要となることを意味している. 類似業界の業者の立場からある程度の推定は可能であっても、通例は、AはBの内情を認識できない立場にある。そこで2次資料などを用いて調査に及び、そのうえで、人工データ生成に要するシナリオを描くことになる.

作成したシナリオは、人工データ生成の基本になるとともに、Aにとって役に立つかどうかという意味(必ずしも客観性ではない)で、生成したデータの「有用性」に係わる.

463

### 3. 作 業 目 標

本実験は、既述のようにAの業態 $P_j$ 進出可否を扱い、その目的を、Yの材料所要量Rの推定のための、X'店の人工データを構築とする.

出力内容は時間別(1時間単位)・週別(最小1日単位)・献立別(昼夜間2分類後の献立を単位)出数(顧客による発注数)である。当面、Y店のRの推定にあるので、1時間より細かい発注時点・献立間の関連・組数は考慮する必要がない。

### 4. X店舗に関する事項とXの写像X'の構築

X店では以下のことが行われているとAは想定する.

- 1) ある週の特定日  $(D_a)$  を予測日,翌週の特定日  $D_{a+b}$  ないし特定期間  $(D_{a+b}$  から  $D_{a+c})$  を被予測期間,予測日における過去の特定日  $D_{a-d}$  ないし特定期間  $(D_{a-d}$  から  $D_{a-e})$  をデータ期間とする.
- 2) 予測日において、データ期間のデータを用いて、被予 測期間の材料所要量Rを推定している.

本実験では、これに準じて、Aの立場で、データ期間のデータ X'を人工的に構築することになる。AがXについて既知 (=確実に知りうる) なのはおもに外形的事項である。比較的に主観の入りにくい「客観的」な内容をともなうものである。それ以外の事項は、おもに店舗、場合によって商品センターや C/K (セントラルキチン) からの配送現場、ネットへの投稿内容などから情報を得る。いわば、既知+観察の2種類の情報から、Xの稼働を推定し、X'に内容を付与していく。

X店の立地に関するGeographic, つまりは商圏的要素 (通行量, コミュニティ, 夜間・昼間・DID人口, 駅, 道路など),および不動産的要素 (路面・階数, 駐車場, 店舗面積, 契約期間内の面積当たり月当たり負荷額など) は既知とする (情報①).また, X店を「観察」して得られたデータがある (情報②).数回にわたり観察日を設け, 時間別顧客入店数・駐車場稼働・座席稼働・オーダーの状況などを記録する.

この情報①と②から推定してXの写像X'を構築する. すなわちX'の人工データを生成する. その条件は以下のaからiに至る各項とする.

- a: データ期間. データを収集する時期・何年何月のどの週. 以下はデータ期間での値である.
- b: 献立 (ランチ・ディナー別) の名称と上代. ABC分析 に準じて限定したほうがよい結果が得られる.
- c: 献立のレシピエ (ポーション単位).
- d: 献立出数比率 (ランチ・ディナー別). ここでは月単位 の平均で推定していく. 季節性は別途に決める. お子さま用は g 項との兼ね合いで別途に決める.
- e:曜日別・時間帯別座席稼働率、稼働率は「入店客/X'店 全座席数」で計算する、入店客は1アイテム(この場合 は主要献立からの選択)を1単位発注する、なお、 座席稼働率は机稼働とは別の概念であることに注意 する、また、商品間の関連、組み(組数・組人数)単位

での発注,平場・個室・キッズの別,組数・組人数は 考慮しない.

- f: ばらつき傾向. X'店の売上の変動は激しいのか, なだらかなのかを決める. なお, 煩雑になるのを予定するなら, この傾向をメニューごとにきめてもよい. つまり, 行:曜日, 列:時間帯のマトリックスがメニュー分となると莫大な量になるが, それにみあう結果がでるなら, 実行してもよい.
- g: 強気・平均・弱気の指定. X店の現状は「イケイケ」 か「衰退気味」なのか決める.
- h: 経営者の方針. 材料所要量決定の方針である. 自信満々 か心配症か決める.
- i: 別途に推計する売上による「データの妥当性」を検証.
- j: その他 略.

## 5. 週の曜日属性・週属性の決定と時間帯別座席稼働数 表の作成

前項のX店舗に関する事項の内容が週の曜日により異なるかどうか(週の曜日属性)を、観察から得られたデータにより決める。また、予測日、被予測期間が確定したら、該当日は通常の週か、異常週か否か(週属性)を判断する。確率的事象に拠らないで客数の動向が決まるものを峻別する。おなじ傾向を持つ曜日はまとめて扱う。

これに時間帯をくみあわせ, 座席稼働表を作成する. 別途, グラフにより、妥当性の心証を得る.

具体的な計算法については以下に依る.

### $C = O \times Seat \times BB$

ここで、座席稼働数 (入店客数):C、座席稼働率:O、座席数:Seat、強気/弱気係数:BBを示す。

また, 座席稼働率は以下の行列式に示される.

$$O = o_{g+h\,j} = \begin{bmatrix} o_{g+11} & o_{g+12} & \cdots & o_{g+17} \\ o_{g+21} & o_{g+22} & \cdots & o_{g+27} \\ \vdots & \vdots & \ddots & \vdots \\ o_{g+h\,1} & o_{g+h\,2} & \cdots & o_{g+h\,7} \end{bmatrix}$$

gが開店時間,hが経過時間.時刻 (g+h) は24進法である.jは各曜日で,以下のように表わす.ここで,g=0は午前0時を意味する.本稿では時間単位とするため,hは常に整数である.経過時間1時間を単位として出数を計算する.また,中抜け営業 (たとえば昼下がりを営業しない)の場合は,1日のうちに開店時間と閉店時間が2回定義される.

$$h = \{1, 2, \dots, 24\}, j = \begin{cases} 1 & \beta \vec{w} \beta \\ 2 & \psi \vec{w} \beta \\ 3 & \psi \vec{w} \beta \\ 4 & \psi \vec{w} \beta \\ 5 & \psi \vec{w} \beta \\ 6 & \psi \vec{w} \beta \\ 7 & \beta \vec{w} \beta \\ 7 & \beta \vec{w} \beta \\ \end{cases}$$

夷 1	スプレハバ	ドシー	トに実租し	た時間帯別座席稼働率
4X I	ヘノレン	コン	1 コレイメンボし	716 时间市州华市修制学

経過時間(h)	終了時刻	月(1)	火(2)		日(7)
1	g+1	$O_{g+11}$	$O_{g+12}$	• • •	$O_{g+17}$
2	g+2	$O_{g+21}$	$O_{g^{+}22}$	• • •	$O_{g+27}$
3	g+3	$O_{g+31}$	$O_{g+32}$	• • • •	$O_{g+37}$
24	g+h	$O_{g+h1}$	$O_{g+h2}$		$O_{g+h7}$

なお蛇足ながら、営業時間(bh)は以下となる.

### $bh = \max(h)$

以上を踏まえて実際に座席稼働数を構築していく.ここで,月~木間及び土日間は観察から同じ傾向があると判断した.そこで,月~木,金,土日に峻別し,以下のように時間帯別座席稼働率を入力した(表2).

表2 時間帯別座席稼働率の数値入力例

時刻	月~木	金	土日
17時	0.05	0.1	0.2
18時	0.15	0.2	0.3
19時	0.35	0.4	0.5
20時	0.25	0.3	0.4
21時	0.05	0.1	0.2
22時	0.05	0.1	0.1

つぎにSeat = 100, BB = 1として, Cを計算した. 算出した座席稼働数 (C) を以下に図として示す (図1).

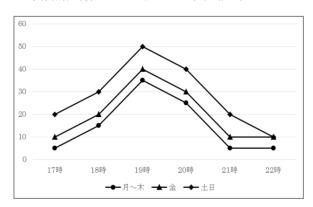


図1 表2を基に作成した座席稼働数の推移

## 6. 予測対象献立とその平均出数

X店の献立を公表メニューから、月単位のABC分析の結果を推定しつつ、特定の献立を特定する。

データ週・被予測週は同一季節とする.季節性が異なり季節特有の献立がある場合は,またお子様用の献立を考慮する場合は、別途の作業が加わる.

以上の作業により本予測に用いる対象献立を特定し、たと えば月平均の出数の比率を推定する.

Xを観測の結果から、仮想的にABC分析を行い、X'に反映させる、経験的にいえば、このABC分析はこの作業の成果を占う重要な作業である。

表3 スプレッドシートに表現した推定されるアイテムの出数比率

Item	$I_1$	$I_2$	$I_3$	• • •	$I_k$
Price	$Mp_1$	$Mp_2$	$Mp_3$	•••	$Mp_k$
Ratio	$r_1$	$r_2$	$r_3$		$r_k$

表4 アイテム別出数比率の数値入力例

Item	$I_1$	$I_2$	$I_3$	$I_4$	$I_5$	$I_6$
Price	1380	1980	2680	3480	980	680
Ratio	7%	7%	20%	10%	35%	21%

推定した月平均の出数の比率は、以下のようにスプレッド シート上に表現できる(表3).

仮想的なABC分析の結果をもとに対象献立を決定した. また、アイテム別の出数比率を入力した(表4).

### 7. X'店の出数推定と予測結果

前節5., 6.で提示した座席稼働図数と各アイテムの出数比率をつかって、X'店のあるアイテムの出数を推定する.

例えばあるアイテム $I_k$ の出数 $N_k$ は以下の式により導かれる.

$$N_k = C \times r_k \times d$$

ここで、*d*は出数のバラツキを表す確率変数である。例えば、正規分布を仮定して以下のように設定すればよい。

$$d=N(1,\sigma)$$

ただし、計算が飛躍的に膨らむ可能性も検討しながら、 進める必要がある。

バラツキ  $(\sigma)$  が大きい場合には、 $\beta$ PERT分布や三角分布を仮定し、三点見積もり法を援用すれば、マイナスの数を出さなくて済むので、計算はある程度減らすことができる。

この作業をk個のアイテムすべてに対して実施する. 最後に、確率変数を含んだNに対してMonte Carlo Simulation を行う.

実際に表2, 表4で設定したパラメータを用いてMonte Carlo Simulationを行った. このとき $\sigma$ =0.25とした.

そのときの各アイテムの出数のサンプルパスを図に示した (図2).

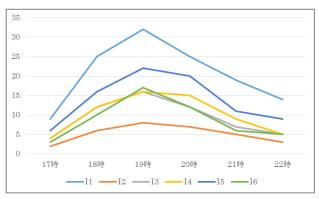


図2 各アイテムの時間帯別出数

表5 アウ	トプッ	トの例	(スプレ灬	ドシー	トの抜粋)
-------	-----	-----	-------	-----	-------

				7							
				$I_1$						$I_2$	
時間帯	17時	18時	19時	20時	21時	22時	17時	18時	19時	20時	
	12	32	47	45	34	29	4	12	18	14	
	12	38	44	50	37	32	4	12	13	15	
	13	33	41	41	32	27	5	10	16	16	
	12	31	55	51	37	29	4	13	14	16	
	13	29	44	51	37	29	4	10	15	17	
	14	31	38	45	36	25	4	11	16	17	
	13	30	53	41	33	25	4	10	19	16	
	12	32	50	42	34	33	5	9	14	14	
試行値	13	34	46	49	36	28	4	11	16	14	
	12	35	48	49	33	35	4	13	17	14	
				:						:	
	12	29	46	44	39	31	4	10	13	12	
	15	36	43	44	40	28	5	11	18	13	
	11	34	48	50	37	34	4	10	16	17	
	14	32	44	48	33	34	4	12	16	16	
	11	29	56	44	39	31	4	9	14	15	
	11	32	52	37	38	29	3	11	17	17	
SD	1	3	5	4	3	3	1	1	2	2	
AVE	12	33	47	45	35	30	4	11	16	15	l l
AVE+SD	13	35	52	49	38	33	5	12	18	16	
AVE-SD	11	30	42	40	32	27	4	10	14	13	

Monte Carlo Simulationの試行回数分だけ結果が出力される. そこから被予測期間分だけ選択する. その選択は任意に行われ, アウトプットとしてスプレッドシートに表現される. (表5)

#### 8. Y店の材料所要量の推定

材料 (M) はアイテム  $(I_k)$  の構成要素と考える. つまり, ある献立 (= アイテム) は材料を調理した結果である. ある アイテム  $(I_k)$  と材料 (M) の関係は以下のようになる.

 $M \in I_k$ 

アイテム  $(I_k)$  に対して材料 (M) の種類は複数ある.

$$I_k M = \{I_k m_1, I_k m_2, I_k m_3 \cdots I_k m_n\}$$

あるアイテム 1単位、ポーション (P) を構成する材料 (M) には、複数の材料  $(I_k m_1, I_k m_2, I_k m_3, \cdots I_k m_n)$  があり、それぞれのポーションは  $(p_{I_k m_1}, p_{I_k m_2}, p_{I_k m_3}, \cdots p_{I_k m_n})$  である.

$$P_{I_k} = \left\{ p_{I_k m_1}, p_{I_k m_2}, p_{I_k m_3} \cdots p_{I_k m_n} \right\}$$

よって、予測期間に含まれる某日  $(D_{a+b})$  の、アイテム  $(I_k)$  の材料  $(p_{I_km_n})$  の出数  $(N_k)$  に対応する所要量  $(R_{I_km_n})$  は、以下のようにあらわされる.

$$R_{I_k m_n} = \sum_{h=1}^{bh} N_{kh} \times p_{I_k m_n}$$

念のため、 $N_{kh}$ は開店時からh時間経過後のアイテム  $(I_k)$  の出数をあらわす.

なお、CKでアイテムごとに材料所要量が管理されていることを前提にするので、材料それ自体の内容のバラツキは考慮しない、すなわち、均一に加工されて店舗に供給される.

ある時間帯における献立を構成する材料とその所要量を 以下の表に示した(表6).

Xの献立を観察し推定されるポーションを決定した.(表7) そして,表5で得られた試行値の平均値(AVE)や平均値 ±標準偏差(AVE±SD)などの代表値を用いて材料の所要

表6 スプレッドシートに表現した献立と材料量

アイテム	1	1	$I_2$		
材料	単位量 所要量		単位量	所要量	
$m_1$	$p_{I_1m_1}$	$N_1 \times p_{I_1m_1}$	$p_{I_2m_1}$	$N_2 \times p_{I_2m_1}$	
$m_2$	$p_{I_1m_2}$	$N_1 \times p_{I_1m_2}$	$p_{I_2m_2}$	$N_2 \times p_{I_2m_2}$	
<i>m</i> <sub>3</sub>	$p_{I_1m_3}$	$N_1 \times p_{I_1m_3}$	$p_{I_2m_3}$	$N_2 \times p_{I_2m_3}$	
	•••				
$m_n$	$p_{I_1m_n}$	$N_1 \times p_{I_1m_n}$	$p_{I_{2m_n}}$	$N_2 \times p_{I_2m_n}$	

表7 X店の献立から推定される材料所要量

		1	D		
	1	1	$I_2$		
材料	単位量	所要量	単位量	所要量	
$m_1$	150	7,050			
$m_2$			200	3,200	
$m_3$					
$m_4$			30	480	
$m_5$			10	160	
$m_6$	20	940	20	320	
$m_7$	80	3,760	80	1,280	
$m_8$	40	1,880			
$m_9$	30	1,410	30	480	
$m_{10}$	40	1,880	40	640	

表8 時間帯別アイテム別材料所要量(抄)

++#31				$I_1$					$I_2$	
材料	17時	18時	19時	20時	21時	22時	17時	18時	19時	20時
1	1,815	4,913	7,065	6,728	5,318	4,475	0	0	0	0
2	0	0	0	0	0	0	810	2,150	3,170	2,970
3	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	122	323	476	446
5	0	0	0	0	0	0	41	108	159	149
6	242	655	942	897	709	597	81	215	317	297
7	968	2,620	3,768	3,588	2,836	2,387	324	860	1,268	1,188
8	484	1,310	1,884	1,794	1,418	1,193	0	0	0	0
9	363	983	1,413	1,346	1,064	895	122	323	476	446
10	484	1,310	1,884	1,794	1,418	1,193	162	430	634	594

量の計算を行う.表5の平均値を用いてスプレッドシートで計算した時間帯別、アイテム別材料所要量を以下に示す.(表8)

### 9. ファッション小売事業との比較

### 9.1 マーチャンダイジング (MD)

店舗を伴う事業は、何らかの商品(モノ・サービス)を準備し、店舗の中にその一部ないし全部を陳列し、その旨を外示する必要がある。物販の場合、この作業をMDと呼ぶ。

店舗に訪れる顧客は概ね店の周囲に存在しているから, 事業者は店の事業を認知できるように情報を発信する. 顕在 顧客に加えて, 潜在顧客が存在する空間を商圏と呼ぶ.

MDは事業内容で異なる. ここでは料飲に比べ,ファッション事業(何らかの業態の小売)では、格段に複雑になり、思考過程で相当の「省略」を不可避とする. ファッション事業のMDに関する初歩的な説明[1]から、その実行に至る思考過程を推察してみる.

#### 9.2 情報収集とその集約

シーズンを設定し情報収集する.ソースは,専門誌,ファッション雑誌,展示会,業界誌紙,コレクション.若干気になるのは,これらメディアの書き手たちはどこから情報を仕入れるのだろうか.顧客や競合他社が既知で自店が未知を避けるべく,媒体にある情報のある部分に,事業者の思考よりも説得力をもつ内容を求めて情報収集する.しかし,情報過多,追従,デッドコピー,未消化を招き,時間コストの上昇を生じさせる

収集した情報はおそらく雑多な内容であろう。たとえば、そのなかに「(顧客に)よく読まれているファッション誌・・・トレンドを取り入れた商品の着こなし方やコーディネート特集・・・」を多数収集できたとしても、なんらかの集約がなければ意味がない。結局取捨し総合し、店で顧客に提案する「姿」「形」を想起し、しかるのちにそれに必要な商品群を連想するのであろう。「姿」「形」は関連するアイテム(「姿」「形」の部品)、その組合せの指示、素材・カラーなど、のちのMD作業に有用な情報と導き出し、MD作業を指示説明するものでなければならない。

### 9.3 設計者の提案と制約

その「姿」「形」は店の商圏に存在する顕在・潜在顧客に対し、一定の説得性が必要になる。結果的に、描かれた「姿」「形」は、従前の実績にもとづくライフスタイルや来店者の傾向の変化分などを制約要件と受け止めて考慮した内容となる。あくまで自らの店のためのものであって、一般性は不要である。

このとき、制約要件がどこまで厳格か(「姿」「形」を描く者にどの程度裁量を認めるか)はさまざまである。日本の百貨店アパレルなどを概観すると、設計者(デザイナー)が数値責任を持つ例は稀で、MDがデザイナー役を兼ね、数値責任を負うように見うける。この「姿」「形」は商圏から支持されるかもしれないし、支持されても、激しい競合を招いたり、逆に、反応が弱い場合もあり、「姿」「形」を描いた段階でリスクが潜むことになる。

#### 9.4 SKUへの翻訳とその制約

そのリスクを承知で一定の期限までに描いた「姿」「形」を商品に翻訳しなければならない. MD (ことに買い付けないしOEM 発注) できるのは、「姿」「形」それ自体ではなく、SKUで説明可能な仕様書であり発注伝票に記載される商品であるからだ[注4]. この翻訳作業で、「姿」「形」を描いた段階で潜むリスクが解消されることもありうる.

この翻訳作業はいくつかの制約要件(以下箇条書きカッコ内は例示)を充足しなければならない. ①アプリオリに計算された数字(売上・仕入・粗利益など), ②前期実績(定番比・売れ筋傾向・在庫回転), ③競合店(類似業態・ポジション・商品のバッティング), ④帳合関係(上代商い, 掛け率, 1都市1帳合い), ④取引条件(サイト・返品・発注頻度・ロット・仕切り価格), ④設計(自主・共同, PB), ⑤OEM先(QCD

や工程能力,テキスタイルメーカー関係),⑤売場(面積や ゾーニング・動線),⑥素材(新素材),⑦陳列(VMD), ⑧販売用什器備品(棚・ラック・ケース・ボディ)・店舗空間(壁・柱),⑧展開(時系列,週単位の売上・粗利・仕入・ 在庫),⑨物流(商品センタ),⑨販売員の理解(説明・推奨力) などがよく解説の対象になる[注5].

SKU単位の商品は、当初の「姿」「形」にもとづいて、売り場で総合され、顧客への提案となる。仕入れた商品をどう売ろうと小売り側の裁量だが、直営ないし取引に対し、諸般の事情から、必要に応じ、売り場の陳列や商品説明その他の事項のプレゼンテーションが必要になる。

#### 9.5 実績のフィードバック

期中の実績に応じて、①期中の追加(高回転狙い)、②打ち切り(可能かどうかは別として)、③シーズンライフサイクル(立ち上がり作業の追加)、⑤競合先展開(バッティングの緊急回避)、⑤仕入スケジュール(在庫レシオ)など当初のMDを変更する作業がある。

POS データは販売実績のデータベースである。ここから データの情報処理を経て、現状を把握し、掲記例示のような 所要の対応策を考える。SKU(品番)はタグのバーコードで 表示されるが、そこにはいかなる独立変数を有するのであろ うか

ひとつのSKUで表示される商品は、およそ以下の表の ①から⑧にあるような独立変数を背負って売り場に登場し、 ときに販売員の介入も交え、顧客に接する(表9).

その動態は、あらかじめ定めた基準⑨に従って計算され、 その結果⑩がデータベースに格納され、折に触れ評価される.

表9 ファッションビジネスのマーチャンダイジング

事項	独立変数等の例
①名称等	商品名,部門・MD,商標,ブランド(差別性)
②「姿」「形」	形 (アナログ), 色, サイズ. 設計者・設計主務者. イラストレーション, パターンメーカー. コメント.
③損益	売価 (上代),原価 (下代),値入,値引,ロス.
④物性	使用素材, 付属品, 品質, サイズ, 洗濯表示.
⑤製造工程	パターンメーカー, CMT, 納期, 品質検査 (テキスト), 縫製レベル
⑥物流	乙仲 (国際物流), 搬送事情, 商品センター入庫, 発注伝票と商品照合, 検品, クレーム, 出庫, 店頭展開.
⑦取引	発注担当者名,起票,仕入先名,数量,掛け率, 買取り,委託,その他仕入条件,バックマージン,売切,追加見込量・追加日程.
8コメント	コーディネート例, 競合他社, 差別化, オリジナル, 独自性
9設定	利益 (粗利・営業・経常) 計画, 売上・仕入・ 値入・在庫・ロス・販管費各予算 (全体・アイ テム別). 目標回転回数.
⑩演算結果	基本項目(売上・仕入・粗利・在庫) はじめ, 各種の利益,消化,上下代合計,平均販売単価, ロス,在庫などを演算する

つまり、①から⑧の各事項は、あらかじめ設定した数値⑨ と比較するため、予実分析、生産状況、ピーク期前後の仕入 推移、 昨年対比など、年間・上下期・シーズン・月・週・ 日単位で計算⑩される.

同時⑩によって、部門・グループ・アイテム別の比較を行い、基本項目などについて成果を競わせる。演算結果は、商品を筋別(売れ筋・見せ筋・死筋)に峻別させる。

販売員からの店頭顧客事情や接客情報をテキストで収集, RFIDによるフィッティング履歴,などにつき,アイテムや特定品 番群につき報告させデータベースに格納する.次期予算の立案に 寄与させとともに,事業全体の商いの勢いを定性的に把握する.

#### 9.6 ファッション事業の人工データ

人工データの先行研究は多々あるが、ファッション事業の人工データは容易には生成できない。レシートの数値を拾うなら可能だが、SKUに紐付されたデータは膨大である。これは、ファッション事業のMD作業が通論で描き尽くせるほど、容易ではないことを示唆する。

MDの通論では独立変数が多数ある旨を示し,事項を列挙する.しかし,多数の変数を認知し,客観的に合理的に決定することは困難である.よって実務の決定過程では相当に省略され,決定の費用と時間を節約する.書き言葉では描ききれないゆえか,MDの通論はこのことにあまり触れない.

### 10. 売上データ推定作業と店舗が扱う商品属性

これまで、売上データを推定する際に考慮すべき変数は、店舗が扱う商品の属性により大きく異なることを、料飲及びファッション小売という性質の異なる事業分野を背景に検討した、売上は金額・数量の両面で管理するが、その前提にアイテム(おおむね品番・商品コードとして具体化する)がある。本稿での事業分野でいえば献立とSKUが基本になる。これに来店客数・買上率を掛け合わせて数量、さらに単価を掛け合わせて金額、そして期間を定め合計した数値が売上になる。この作業は日々POSレジが稼働してデータ化され、統合データベースに格納する(大規模事業ならERPなどを想定)。

さて、厄介なのは、品番ないし商品コードにひも付されるデータである。料飲事業であっても献立に「チョイス」が加われば途端に複雑になるが、ファッション衣料ではその日ではなく、SKUを単位に商品を定義しても、そのひとつの商品に膨大な情報がつきまとう。

これらの例で明らかにしたように、売上データの予測は、 変数の数に業態による違いはあるものの、多変数関数を扱う ことになる.

独立変数を $x_i$ (i=1, 2, …, N)、売上データの予測値を $\Sigma$ とすると

$$\Sigma = \Sigma (x_1, x_2, \dots x_N) \tag{1}$$

である. (1) 式が成り立つためには、独立変数 $x_i$ は連続変数でなければならない。

しかし、例えばファッション製品の場合、色や素材の材質など、連続変数に分類できない変数もあるが、このような問題にはここでは立ち入らないことにする。何らかの処理、例えば多変量解析などの手法を用いて、適当な数量化を行うことにより、連続変数化することができるものとして以下の話を進めることにする。

(1) 式を偏微分することにより、予測値の変動はそれぞれの独立変数に依存して

$$d\Sigma = \frac{\partial \Sigma}{\partial x_1} dx_1 + \frac{\partial \Sigma}{\partial x_2} dx_2 + \dots + \frac{\partial \Sigma}{\partial x_N} dx_N \tag{2}$$

のように変化する. (2) 式右辺の各項は正の値を取るばかりでなく, 負の値も取りうるので, 予測値の変動は最大で

$$\left| d\Sigma \right| = \left| \frac{\partial \Sigma}{\partial x_1} dx_1 \right| + \left| \frac{\partial \Sigma}{\partial x_2} dx_2 \right| + \dots + \left| \frac{\partial \Sigma}{\partial x_N} dx_N \right| \tag{3}$$

となる.

実務的な問題として、すべての変数を扱うのは不可能である。このため、それぞれの独立変数に対する偏微分係数の大きさと、独立変数の実際的な変動量を考慮して、(3)式の左辺に大きな影響を及ぼす項を抽出し、これらの値を用いて売上データを推定するという作業を行うことになるであろう。

この時抽出された独立変数の数をnとすると、実際の実務で推定されるべき値は、以下の式になる。

$$\left| d\Sigma \right| = \left| \frac{\partial \Sigma}{\partial x_1} dx_1 \right| + \left| \frac{\partial \Sigma}{\partial x_2} dx_2 \right| + \dots + \left| \frac{\partial \Sigma}{\partial x_n} dx_n \right| \tag{4}$$

 $\Sigma$ を決める独立変数 $x_i$ を正確に決めることができれば、無駄なく商品を売り切ることができ、ロスを生じることもない・・・と信じられてきた。

しかし、業態にもよるが店舗に訪れる客は変化し、これに伴って客の嗜好も変化する。そのため、最適な売上予測を行うことは不可能である。それでも、できる限り損失を被らないようにするためには、何らかの形で売上予測を行うことは必須である。そこで以下のようなマネジメントの思想を受けるれる

客観的に正しい解を得ることは不可能だが、主観的に 「正しい」解、つまりはbetterな解を得ることは可能である. 要は主観的合理性の導入である.

各独立変数 $x_i$ の値は、これらの予測作業を行う人や組織、また使用可能なデータの量と質などにより的確度が異なるであろうが、理想的な作業の下に決定することのできる $x_i$ の真値 $x_i$ が存在すると仮定することはあながち間違ったことではないと考える.

そこで、売上データの推定作業によって決定される $x_i$ の値は、真値 $X_i$ の値を平均値とし、一定の分散を持つ正規分布

$$N(X_i, \sigma_i^2) = \frac{1}{\sqrt{2\pi\sigma_i}} \exp\left(-\frac{(x_i - X_i)}{2\sigma_i^2}\right)$$
 (5)

に従うと仮定することができる.

実際の実務においては、他店舗のデータを参考にするか、あるいは、すでに営業を行っている自店舗の過去のデータを利用して売上予測を行う。これらのデータの質と蓄積された量により、決定された各独立変数 $x_i$ の精度(したがって分散  $\sigma_i^2$ 、または標準偏差 $\sigma_i$ )の値は異なるであろう。

しかし、実務を繰り返すことにより蓄積された経験と勘により、 $\sigma_i$ と $d\Sigma$ を決める偏微分係数 $\frac{\partial \Sigma}{\partial x_i}$ の値は、徐々に制度を増していくであろう。

このようにして、(4) 式を最小化する各独立変数 $x_i$ とこれらによって決定される $\Sigma = \Sigma(x_1, x_2, \cdots x_N)$  の値を決めていくことができる.

#### 11. 品番・商品コードと製品設計の関係

料飲事業では献立は厨房のトップないしは事業者みずから決める。ちなみに割烹の場合は伝統的には料理長(芯・板ないしは板長という)の専決事項である。「喰切り」を旨とするので客には見せない(現代とはだいぶ様子が異なる)、板場という調理空間でのみ通用する隠語で書かれる(たとえばお造りは造里などと書く)、品番設定はすなわち設計そのものである。いちいち絵に描かなくても、顧客に提供する「商品」はできてしまう。

一方,ファッション小売で,今や主流のファストファッションはその業態をSPA (製造兼小売)に求める。店のPOSレジに読ませる品番は出荷者が設定し、同時に小売価格もタグに付する。商品の設計は「設計主務者」が営業部門や購買担当者と協議して決める。以上はZaraの場合である。

メゾンないしクチューメゾンでは相談するかどうかはともかく「設計主務者」が専決する.

すなわち、人工データ構築の過程は、商品の設計過程と 密接な関係があることを示唆している。このことは、ファッション衣料の設計を解き明かす(定式化する)さいに、重要 なヒントを与える。その内容は別の論文で扱う。

### 分 担

本稿は、大谷のアイデアを、吉岡がExcelおよび行列式等で表現したものに、さらに高橋が工学的な考察を加えた.

#### 謝の辞

本研究は12-16年度科研(基盤研究S)24220012「国際市場を前提とする服飾造形とテキスタイルの設計提案に関する技術的経営的研究」の助成を受けた。

### 注

[注1] 人工データの手法は、データマイニングや複雑系などの 立場から、種々議論されている。一般論や方法論も有効 な議論である。

https://staff.aist.go.jp/s.akaho/thesis/thesis-www/node51.html

だが、本稿では relevancy を重視する. たとえば物販では以下のような試みがある. 本視点からすれば、これでもまだ一般的であるとする.

#### http://musashi.osdn.jp/artificialData/

- [注2] いわゆる業界事情にかかる平均的理解が出発点になるのであって、白紙からという例はめったにない、その場合はM&Aの方が有効だが、ただしリストラクチュアを敢行する能力が必須となる.
- [注3] たとえば、Conventional Systems、Cook Serve System、Lady Food System (Cook-Chill, Cook Freeze, Sous-vide/Vacuum Cooking)、Commissary System (Central Kitchen System)、Assembly System などに関する理解、
- [注4] Stock Keep Unitの略. 商品を識別する最小単位の品番. ファッション衣料では「型」のあとの色・柄・サイズのレベルで設定する.
- [注5] 料飲事業でも、顧客に選択の余地を許容する方法(ライス orパン、肉 or魚、バイキング形式、デザートやドリンクのセットの希望有無など)を採用すると、コード設定が格段に複雑になる。

### 参考文献

[1] 文化服装学院編:ファッションビジネス 流通応用編, 文化出版局, pp.40-56, 2014.



**吉岡 佑磨** (学生会員)

2016年 信州大学大学院理工学系研究科繊維・感性工学専攻修士課程修了. (株)ループコンサルティング非常勤研究員. 同年4月以降, グンゼ勤務.



髙橋 下人 (正会員)

東京工業大学大学院理工学研究科高分子工学 専攻博士課程修了博士(工学).東京都立大学 工学部工業化学科助手を経て信州大学繊維学 部感性工学課程准教授.専攻高分子材料学, シミュレーションを用いたリスク管理に関す る研究.



大谷 毅(正会員)

1975 年 明治大学大院経営学研究科博士課程 単位取得退学. 信州大学経済学部・繊維学部, 宮城大学事業構想学部各教授. 2009 年 信州 大学名誉教授・研究特任教授. 博士 (学術), ファッション事業研究に従事.