

# 進化型神経回路網モデルによるデータ駆動型ブランディング手法の提案

綿貫真也<sup>†1</sup> 長尾智晴<sup>†2</sup>

**概要:** マーケティングにおいて、ブランディングは重要な戦略である。特に、競合との差別化を明確にするブランド・ポジショニングと自社内のブランド体系を整理するブランド・ポートフォリオは、重要な戦略策定課題である。従来、両戦略課題に対して、仮説検証型の構造方程式モデル (SEM: Structural Equation Model) が有効であった。しかし、近年のデータリッチなマーケティング情報環境においては、多くのデータから迅速な仮説生成と検証が求められており、事前に明確な仮説を持たない段階では SEM の構造決定は難しい。こうした中で、データ駆動型ブランディング手法が求められている。本研究では、SEM の中でも、パス解析モデル (PAM: Path Analysis Model) に焦点を当て、ブランディングのための構造決定をデータ駆動的に行うアプローチとして進化型神経回路網モデルの一つである Real-valued Flexibly Connected Neural Network (RFCN) の応用が有効であることを示す。

**キーワード:** 進化型神経回路網モデル, 遺伝的アルゴリズム, ニューラルネットワーク, 構造方程式モデル, ブランディング

## Data-Driven Branding Approach using Evolutionary Neural Network

SHINYA WATANUKI<sup>†1</sup> TOMOHARU NAGAO<sup>†1</sup>

**Abstract.** Branding is the key strategy in marketing. Especially, brand positioning and brand portfolio are important tactics to success brand strategy and Structural Equation Model (SEM) has been a useful method to analyze these tactics. SEM was an appropriate approach for testing hypotheses. However, in recent years, it has been difficult for researchers and marketers to determine SEM structures in an environment full of marketing data without having clear hypotheses in advance as they are required to rapidly make and test hypotheses from immense amount of data. Therefore, a data-driven branding approach has been requested. In this study, we will focus on Path Analysis Model (PAM) which is a method of SEM and demonstrate the usefulness of our data-driven method to build SEM for branding using Real-valued Flexibly Connected Neural Network (RFCN), which is a kind of evolutionary neural network model.

**Keywords:** Evolutionary Neural Network, Genetic Algorithm, Neural Network, Structural Equation Model, Branding

### 1. はじめに

ブランド戦略において、ブランド・ポジショニングとブランド・ポートフォリオは競争市場環境における当該ブランドの市場投入の成否を分ける重要な戦略課題である [1] [2]。ブランド・ポジショニングとは、競合ブランドに対して差別優位性を獲得するために重要な施策である。ブランド・ポートフォリオは、自社内の複数のブランドが市場において、カニバリゼーション(喰い合い)を起こさないために、自社ブランド間の特徴を整理する施策である [2]。いずれの施策も、対競合、対自社グループ内ブランドという違いはあるものの、ブランド間の差別的特徴を明確にすることで、市場において競争優位性を獲得していくという戦略目標を有する点は共通している。これまで、こうした施策は主成分分析、因子分析、コレスポンデンス分析、多次元尺度法といった特異値分解による次元縮約の方法によって策定されることが多かった [3]。この方法は、パーセプションマップ法と言い二次元上で、特徴変数と各ブランドの

バイプロットからその差異を把握するものである。しかし、こうしたパーセプションマップ法では、購買といった意思決定変数との関連を明らかにすることが出来ない。

そうした中で、従来の手法の問題点を解決したのが SEM である。SEM は、先述の主成分分析や因子分析に加えて回

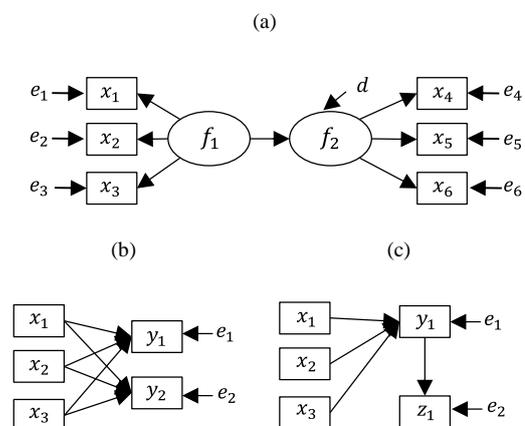


図 1 構造方程式モデル

Figure 1 Structural Equation Model

<sup>†1</sup> 横浜国立大学大学院環境情報学府  
Department of Information Media and Environment Science, Yokohama National University Yokohama, Japan

帰分析をも包摂する数理統計学モデルであり、ブランド戦略を科学的アプローチによって支援するマーケティングサイエンスの重要な手法[5]となっている。SEMは、基本的に潜在変数と観測変数から構成される(図1)。図1(a)において、楕円で記述されているのが、潜在変数である、潜在変数は、直接測定される変数ではなく、分析者の仮説に基づき、いくつかの観測変数から構成される。図1(a)、(b)、(c)において、長方形で記されているのが観測変数であり、観測変数は質問項目など直接測定される変数のことである。特に、観測変数のみで構成されたSEMをPAMと言う(図1(b)、(c))。また、構造方程式モデルをあるシステムを表現する方程式として捉えると、これら変数は、外生変数と内生変数に分けられる。外生変数とは、他の変数に規定されていない変数のことであり、内生変数とは、他の変数から規定されている変数のことである。図1(a)の $f_1$ 、(b)の $x_1 \sim x_3$ 、図1(c)の $x_1 \sim x_3$ は、外生変数である。一方、内生変数は、図1(a)の $x_1 \sim x_6$ 、 $f_2$ 、図1(b)の $y_1, y_2$ 、図1(c)の $z_1$ である。図1(a)~(c)の $d, e$ は、すべて攪乱項である。

通常、図1(a)を多重指標モデル、図1(b)を多変量回帰モデル、図1(c)を逐次型回帰モデルと言う。SEMの構築は、通常、理論的、経験的な観点から研究者・戦略策定者の仮説に基づき、その構造がア prioriに決定される。特に潜在変数が必要とされるSEMの場合において、潜在変数を構成する観測変数の適切性は、信頼性分析におけるアルファ係数によって決定される[6]。この手続きは、潜在変数を主成分分析や因子分析などによって観測変数化し、モデル化する際においても同様である。つまり、SEMにより、ブランド・ポジショニング施策、ブランド・ポートフォリオ施策の策定を試みる際は、戦略策定者は、当該ブランドにおける競争優位となるブランド価値の構造に関して、明確な仮説構築が必要とされる。

そうした仮説に基づき構築されたSEMは、統計的適合度指標によって検証される[5]。近年、マーケティングにおいては、アドテクノロジーの急速な発展によりビッグデータの存在が無視できなくなってきた。それに伴い、ブランド戦略立案において、仮説の構築と検証の迅速な対応が求められてきているのである。実際に、戦略立案の際には、当該ブランドのポジショニング、ポートフォリオについて、ある程度の仮説とデータがあるのみであることが多い。こうしたブランド戦略を取巻く情報環境において、従来型アプローチは仮説検証的アプローチとしては非常に優れているものの、データ駆動型で仮説生成的にSEMを構築し、検証を行う方法に関する研究が多いとは言えない。

## 2. データの収集

本研究では、流通コングロマリットであるセブン&アイホールディングスとイオングループのブランドを取り扱う。

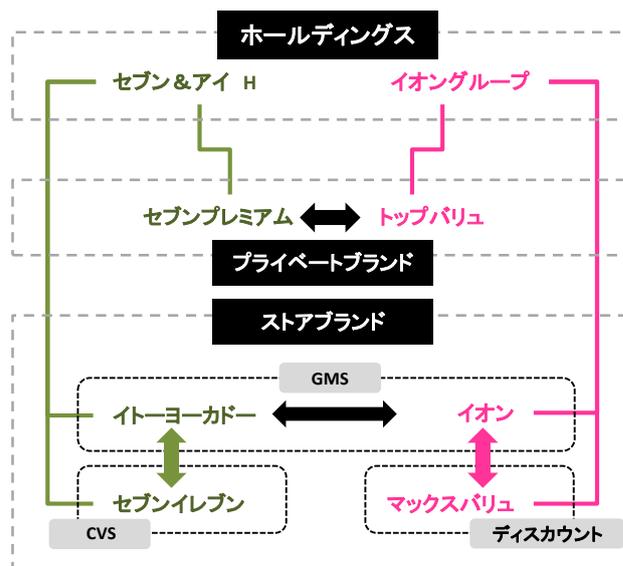


図2 本研究で扱うブランド階層ツリー

Figure 2 Brand Architecture

これは、これらコングロマリットは複数の業態を持ちつつも、類似した競争市場環境においてブランドを参入させており、価格以外のブランド・ポジショニング、ブランド・ポートフォリオ施策の策定がブランド戦略上重要な意味を持つと考えられる。本研究では、両コングロマリットの中でも、主要カテゴリ、ブランドに絞って検討を行う。具体的には、セブン&アイホールディングスにおいて取り上げるブランドは、セブンプレミアム、セブンイレブン、イトーヨーカドー。イオングループは、トップバリュ、イオン、マックスバリュとした。図2では、ブランド・ポジショニング施策対象のブランドグループを太い横矢印、ブランド・ポートフォリオ施策対象のブランドグループは、太い縦矢印で示している。図2に基づき、プライベートブランドカテゴリでは、ブランド・ポジショニング分析(Positioning: PB)を行い、ストア・ブランドカテゴリにおける、GMS業態ではブランド・ポジショニング分析(Positioning: GMS)、同じホールディングス内で業態が異なるブランド間ではブランド・ポートフォリオ分析(Portfolio: 7&i, Portfolio: AEON)を行う。また、ホールディングスブランドについては、事業実態のあるサブブランド群に依拠してブランド価値が創造されていくと考えられるので、本研究では研究対象としない。実査は、インターネットを利用し、株式会社マクロミルが保有するインターネットパネルを用いて行った。調査対象は、セブンプレミアム、トップバリュの購入経験者で25歳から54歳までの首都圏(東京、神奈川、埼玉、千葉)に在住の女性とした(n=840)。購入カテゴリは製品関与度を統制するために、低関与な製品カテゴリである食料品(生鮮、冷凍食品、酒、菓子、飲料など)、日用品(洗剤、ステーションナリー、ヘアケア、オーラルケア、ペット用品など)とした。

表 1 ブランド・パーソナリティ項目

Table 1 Brand Personality

因子	特性			
刺激	話好きな	BP1	人なつっこい	BP7
	ユーモアがある	BP2	朗らかな (ほがらかな)	BP8
	楽観的	BP3	愛想のよい	BP9
	積極的な	BP4	若々しい	BP10
	現代的な	BP5	元気な	BP11
	自由な	BP6	快活な	BP12
能力	一貫した	BP13	忍耐強い	BP19
	責任感ある	BP14	粘り強い	BP20
	しっかりした (頼りになる)	BP15	男性的な	BP21
	堂々とした	BP16	自信に満ちた	BP18
	意思の強い	BP17		
平和	内気な	BP22	平和な	BP24
	おっとりした (温厚な)	BP23		
誠実	暖かい	BP25	優しい	BP27
	気がきく	BP26		
洗練	上品	BP28	おしゃれな	BP31
	素敵な	BP29	洗練された	BP32
	ロマンチック	BP30	贅沢な	BP33
平和	ナイーブな	BP34	子供っぽい	BP36
	さみしがり屋の	BP35		

また、ブランド・ポジショニング、ブランド・ポートフォリオの策定にはそれぞれ、差別化因子を設定する必要があ

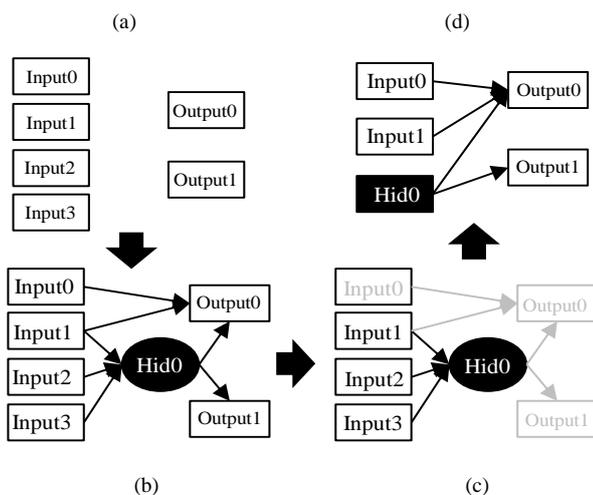


図 3 RFCN による PAM の最適化手順

Figure 3 Process for optimization of PAM with RFCN

る。差別化因子は、価格、機能、ブランドパーソリティな

どがあるが、本研究では、差別化因子としてブランド・パーソナリティを採用し[7]、入力変数として設定する(表 1)。表 1 に示した特性に対して、当該ブランドに当てはまると思われる程度に応じて、5 段階のリッカード尺度(「非常にあてはまる (5)」から「まったく当てはまらない (1)」)によって測定を行った。出力変数は、当該ブランドに関して、高い価格プレミアム性を抱いているグループとした。価格プレミアムの測定は、「XX (ブランド名) が他のプライベートブランドと多少値段が高くて、XX (ブランド名) を購入したいと思う。」について 5 件法のリッカード尺度で質問した結果を集計し、平均値を基準に、当該ブランドについて高い価格プレミアム性を抱いているグループと価格プレミアム性を抱いていないグループに分けることで、当該ブランドに高い価格プレミアム性を抱いている被験者を抽出した。

### 3. RFCN による PAM の最適化

このように、SEM は仮説検証型のアプローチとしては有効であるものの、仮説生成的アプローチが要求される場面では必ずしも有効とは言えない。そこで、本研究では、SEM の中でも、すべての変数が観測変数で構成される PAM に焦点を宛て、当該構造の最適化手法として、筆者が属する研究グループが提案している Real valued Flexibly Connected Neural Network(RFCN)の適用を試みる [8][9]。RFCN は、遺伝的アルゴリズム (Genetic Algorithm; GA) を用いて進化的にネットワークの結合荷重と構造が自動的に決定される。このように RFCN は、問題に応じて適切な構造を進化的に、柔軟に獲得できるという利点を有する。そのため、PAM の構造をデータ駆動型の仮説生成アプローチとして、最適化する方法として有効であると考えられる。パス解析モデルを構築する手順は図 3 に示す。

#### 3.1 RFCN による解析

出力変数は 2 変数で、それぞれ価格プレミアム性を抱いているブランドである。それぞれ、0, 1 のバイナリデータである。入力変数には、ブランド・パーソナリティの 36 変数を設定し、元の値を標準化したデータを解析に用いた。RFCN に対する構造最適化で用いたパラメータを表 2-3 に示す。表 2 に示すパラメータ群は (Gain, Threshold, Weight) は、試行実験の結果、記述性が高いものを選択した。表 3 は通常、RFCN で設定される基本的な関数群である。また、適合度関数を正答率として、下記で求めた。

$$Fitness = \frac{\sum_{i=1}^n Simulated\_PI}{\sum_{i=1}^n Actural\_PI} \quad (1)$$

ここで、 $i$  は 1 から  $n$  までの整数でサンプル数を表す。 $n$

は分析に用いるサンプル数である。Simulated PI は、RFCN が出力する値で Actual PI はもともとの値である。

### 3.2 PCA(Principal Component Analysis)と NN(Neural Network)

PAM を構築する前段階として、収束した RFCN の隠れ層を観測変数として取り扱う必要がある。これは、ニューラルネットワークにおける隠れ層の活性化関数が線形関数である場合には、PCA と等価であるが非線形関数の場合には一致しないということが分かっている[10] [11]。そこで、本研究においても、隠れ層の活性化関数を線形関数とすれば、当該隠れ層に投射している入力変数を PCA で解析することで、算出された主成分得点を隠れ層の情報を表現する観測変数として扱うことができる。しかしながら、RFCN で通常使用される活性化関数は、線形関数のみならず、非線形関数を含む複数種類の関数群によって構成される。よって、Japkowitz and Hanson ら[12]の知見に依拠するならば、理論的整合性の観点から、検討する RFCN についても、線形関数のみで構成される RFCN を適用すべきであるが、手法適用の有効性を検討する範囲を限定したくないので、本研究では、通常の複数関数から構成されるマルチ関数型 RFCN についても検討を加える。以上から、本研究ではマルチ関数型 RFCN と活性化関数が線形関数のみで構成される線形関数型 RFCN の両 RFCN の結果について検討を行う。

### 3.3 PAM の構築

RFCN により求められる構造と PCA の結果から、PAM をそれぞれ構築する。本研究における PAM は、目的変数 (RFCN の出力変数) カテゴリカルデータであるために、解の推定方法は最尤法ではなく、the weighted least squares mean- and variance-adjusted (WLSMV) 法[13]により求める。以上の手続きを経て、構築された PAM は、統計的適合度指標により、その妥当性が検証される。本研究では、統計的適合度指標として、一般的に使用されることの多い root-mean-square error of approximation (RMSEA) [5], weighted root-mean-square residual (WRMR) [13], goodness-of-fit index (GFI) [5], adjusted goodness-of-fit index (AGFI)[5], Tucker Lewis Index (TLI) [5], comparative fit index (CFI)[5]を採用する。

## 4. 結果と考察

RFCN の構造最適化は遺伝的アルゴリズム(GA)によって行った。分析対象データの 80%を訓練データ、20%をテストデータとして解析を行った。GA パラメータは、マルチ関数型 RFCN、線形関数型 RFCN ともに試行錯誤を繰り返し適切な値に設定した。そして、表 2 に RFCN の評価を示す。

表 2 RFCN の結果

Table 2 Result of RFCN

Group	Multi-Function RFCN		Linear Function RFCN	
	Training	Test	Training	Test
data				
Positioning (PB/334)	82.40%	68.66%	82.77%	67.16%
Positioning (GMS/146)	88.89%	75.86%	84.62%	65.52%
Portfolio (7&i/418)	84.43%	70.24%	83.23%	73.81%
Portfolio (Aeon/519)	73.73%	60.58%	73.98%	61.54%
Average	82.36%	68.83%	81.15%	67.01%

表 2 の正答率の平均値を見ると、僅かにマルチ関数型 RFCN のほうが高い精度を示しているものの、マルチ関数型 RFCN、線形関数型 RFCN とともに同程度の精度であった。両タイプの RFCN によって、重要でない変数などが排除され、最適化された構造に依拠し、PAM を構築し、解析した。最終的に、PAM の構造は、すべてのグループにおいて、図 1 (b) の多変量回帰モデルの構造に最適化された。例として、Positioning<PB>のネットワークトポロジーとその構造に基づき構築された PAM を図 4 に示す。図 4 (左) が RFCN の結果であり、左の白丸が選択された入力層のノード、黒丸が抽出された隠れ層である。中の文字 GSN は選択された関数で、Gaussian 関数が選択されたことを表している。同様に、右の白丸は出力層のノードであり、中の文字 MDN\_tv はトップバリュノードにおいて、Median 関数が選択されたことを表現している。MDN\_sp は、セブンプレミアムノードにおいて、Median 関数が選択されたことを表現している。図 4 (右) は図 4 (左) の RFCN で獲得されたトポロジーに依拠して構築された PAM のパスダイアグラムである。右の四角が説明変数、左の 2 つの四角が目的変数である。統計的に有意であった変数は赤い二重線で囲み、その変数からのパスは赤色で表現している。四角は観測変数であることを表現している。

マルチ関数型 RFCN に依拠して構築した PAM はすべての統計的適合度指標において良好な結果であったが、線形関数型 RFCN に依拠して構築した PAM は、Positioning<PB>、Portfolio<AEON>においてカイ二乗検定が有意となっており、WRMR も 1 に近く、比較的高い値を示している。以上から、マルチ関数型 RFCN に依拠した PAM のほうが良い適合度を示していると考えられる。従って、ブランド・ポジション分析、ブランド・ポートフォリオ分析は、マルチ関数型 RFCN に依拠した PAM によって推定された回帰係数によって行う。ここでは、ポジション分析 (PB)

のみ、統計的に有意であった変数の回帰係数を表3に示す。

表3 統計的に有意だった係数 (Positioning: PB)

Table 3 Significance of Coefficient (Positioning: PB)

項目	特性	因子	Coefficient		p-value
			Seven premium	Topvalu	
BP13	一貫した	能力		-0.255	0.092*
BP14	責任感ある	能力		-0.316	0.018**
BP21	男性的な	能力	0.211		0.092*
BP24	平和な	平和	-0.318	0.318	0.064*
BP33	贅沢な	洗練	0.701	-0.701	0.000***

\*\*\*p<0.001 \*\* p<0.05 \* p<0.1

(能力) がそれぞれ - 0.255, - 0.316 を示している。この結果は、セブンプレミアムが、「洗練され、かつ猛々しい」パーソナリティが価格プレミアム性に寄与していることを示している。一方、トップバリュは「優しく、穏やかな」パーソナリティが価格プレミアム性に寄与していることを示している。これらの要素が、両ブランドの差別化において重要な特徴となっていることが理解できる。同様に、他カテゴリについても有効な結果を得ることができた。

## 5. まとめ

本研究では、RFCN を用いたデータ駆動型のアプローチによって、仮説生成的に PAM を構築し、検証することでブランド戦略策定における新たな手法を提案した。特に、ブランド戦略において最も重要であるブランド・ポジショニング施策、ブランド・ポートフォリオ施策策定へ向けた分析を行った。その結果、ブランド間の差別優位性を明確に提示することができ、本アプローチの有効性を確認することができた。今後の課題としては、ポジショニング分析、ポートフォリオ分析ともに、取り扱うブランド数を増やし、多数ブランドに拡張することに加え、非設計データへの適用も視野に入れて検討を行っていききたい。

## 参考文献

- [1] Aaker, D. A.. Managing Brand Equity: Capitalizing on the Value of a Brand Name. NY: Free Press, 1991
- [2] Aaker, D. A.. Brand Portfolio Strategy. NY: Free Press, 2004
- [3] 片平秀貴. マーケティング・サイエンス. 東京大学出版会, 1987
- [4] Jolliffe, I. T.. A Note on the Use of Principal Components in Regression. Journal of the Royal Statistical Society, Series C (Applied Statistics). 1982, vol. 31, no. 3, p.300-303
- [5] Kline, R. B.. Principles and Practice of Structural Equation Modeling(4th Edition). NY: Guilford Press, 2005
- [6] Cronbach, L. J.. Coefficient alpha and the internal structure of tests. Psychometrika. 1951 ,vol.16, p.297-334,
- [7] Aaker, J. L.. Dimensions of Brand Personality. Journal of Marketing Research. 1997, vol. 34, no. 8, p. 347-56,
- [8] Agui, T., Nagao, T. and Nagahashi, H.. A genetic method for optimization of asynchronous random neural networks and its application to action control. in Proc. Int. Joint Conf. on Neural Networks (IJCNN '93). 1993, vol. 2, Nagoya, Japan, p. 1893-1896.
- [9] Shirakawa, S. and Nagao, T.. Control of autonomous agents in continuous valued space using RFCN. Electronics and Communications in Japan. 2008, vol. 91, no. 2, p. 762-769,.
- [10] Cottrell, W. and Munro, P.. Principal components analysis of images via back propagation. in SPIE. 1988, vol. 1001 Visual Communications and Image Processing, p. 1070-1077,.
- [11] Boulard, H. and Kamp, Y.. Auto association by multilayer perceptrons and singular value decomposition. Biological Cybernetics. 1988, 59, p.291-294.
- [12] Japkowitz, N, Hanson, S and Gluck, A., Nonlinear autoassociation is not equivalent to PCA. Neural Computation. 2000, 12 (3), p. 531- 545
- [13] Muthén, L. K. and Muthén, B. O.. Mplus User's Guide. Los Angeles, CA, 1998-2001

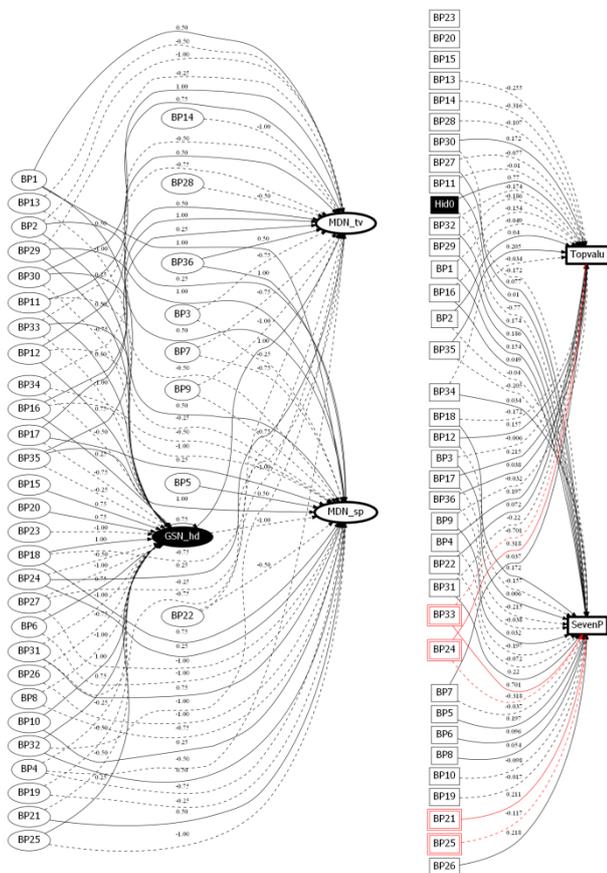


図4 RFCNの結果(左)と構築されたPAM(右)

Figure 3 Network Topology of RFCN (Left) and Path Diagram of PAM Based on the RFCM (Light)

共通変数である「贅沢な」(洗練)の係数を見ると、セブンプレミアムは 0.701, トップバリュは - 0.701 であり、「平和な」(平和)は、セブンプレミアムは - 0.318, トップバリュは 0.318 であった。また、セブンプレミアムの独自変数として「男性的な」(能力)は 0.211 を示し、トップバリュの独自変数として「一貫した」(能力), 「責任感のある」