

データマイニング的手法を用いた適応的需要予測

杉 原 敏 夫

Abstract

Demand forecasting for Supply Chain Planning (SCP) is essential highly to obtain forecasting accuracy and real time outputs reflecting structural market changes. In this study, an adaptive demand forecasting approach adopting the data mining technique which detects the correlations between target factors and other related elements, is proposed. Including the scheme of the time series analysis based on the state space approach, this approach has two characteristic points. One is the state space which is formulated by principal components composed from various market elements. The other is the self organization of the state space using a neural network. In regard to the latter feature, we previously introduced the modified General Method of Data Handling (modified GMDH) method into the self organization mechanism. Consequently, we achieved significantly higher accuracy using this approach compared to the previous approach.

1. SCPにおける需要予測方式への要件

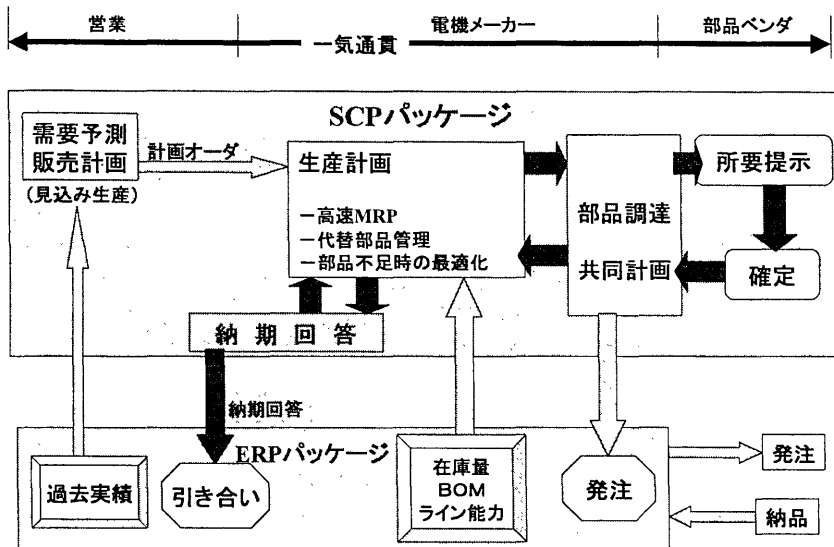
1.1. SCMとSCP

サプライチェーンマネジメント (SCM) についての一般的な概念は「顧客満足度を高め、しかもコストを引き下げよう企業間の供給連鎖の最適な形成と統合、最適な運営を目指すように供給連鎖を管理すること」¹⁾のように示され、今日においては経営革新の中心的な課題と考えられている。SCMは上記の概念定義において示されるように、供給連鎖の最適な形成・統合・運営を目指すものであるが、情報の流れから見れば供給連鎖とは逆の、需要を出発点とする基幹的な情報のシームレスフローに依存している。すなわち、SCMの実現のためには販売サイドから生産サイドへと流通するシームレスな情報に基づき、いかに顧客満足度の向上とコスト低下をもたらす供給連鎖を形成・運営で

きるかということが要求される。

そのための計画機能がサプライチェーンプランニング (SCP) であり、SCM全系における需要計画、物流計画、生産計画を基幹系情報にもとづいて最適化し、SCM全系を制御するものである。SCPから駆動される制御機能としては、近年は個々の基幹系システムを統合化したエンタープライズ・リクワイアメントプログラム (ERP) が採用されるケースが目立っている。すなわち、SCPはSCMにおける実質的な頭脳であり、生産から販売に向かう供給連鎖の計画機能を有するものである。また、ERPはSCPの指示によって動作するSCMの神経系統とでもいうことが出来よう。図1はSCPの一例として、その位置づけとERPとの役割分担を描いたものである。

図1におけるSCPパッケージという表現から、ややもするとSCPは販売、調達、生産に関する計画手法のパッケージと考えら



〔図1. 計画業務とSCP 参照. 参考文献1〕

れるきらいもあるが、これは従来のDSSに見受けられたような手法としての集合体ではなく、SCMというビジネスモデルに埋め込まれた計画機能である。すなわち、ビジネスプロセスの問題を探索し、その解決を行うための支援機能をビジネスプロセスの中で実現しようとするものである。したがって、SCPの適用においては、対象となるビジネスプロセスについての十分な理解と問題意識が要求される。SCPパッケージはそのための十分な解決手段を提供するための部品の集合体とでも言えよう。

1.2. 需要予測の重要性とそのための要件

図1からもうかがわれるように、SCPにおける需要計画の重みは大きい。需要計画はいわば、SCPの計画機能の情報フローの出発点に位置するものであり、そこにおける錯誤はSCM全系において大きな狂いをもたらす元凶となるものである。需要計画の根幹をなすものは需要予測であり、結局のところ、SCPにおいては需要予測はSCMの成否を

左右する重要度の高い要素といえよう。図1に示されている需要計画においては、ERPからの情報として過去の実績が入力されているが、需要予測はそれを基本データとしつつも短期及び中長期的市場環境動向を織り込んだ予測が要求され、しかも生産のリードタイムに対応する計画値を出力する必要がある。また、そのバックボーンとして、実績値の入力に際して即時に予測値を算出するOLAP (Online Analytical Program) 機能が前提とされるべきであろう。以上をまとめてSCPにおける需要予測の特性を挙げれば以下のように記述される。

- 過去の実績の動きに適応した予測方式であり、予測精度が高いこと
 - 実績に対しての逐次的なりリアルタイム処理を基本方式としていること
 - 対象製品の予測と同時にそれを取りまく市場環境の予測ができること
 - 市場環境の構造変化が逐次に予測機構に反映されること
- Aは過去の時系列の動特性の動きを取り込

んだ動的需要予測方式が前提とされるべきであるということである。かつての中長期予測に見受けられたカーブ・フィッティングや回帰式のような静的方式ではなく、刻々と動く時系列の時点ごとの動きをもとにした予測方式であるべきであり、当然ながら高い予測精度が要求されよう。また、SCPの意味合いから考えて、ほぼ短期予測に限定してよいものと考えられる。

BはOLAP処理を前提とするということを示している。需要予測には販売サイドからの随時の入力に対してリアルタイムに予測処理が行われる必要があり、また、要求される任意の時点において即時に予測結果を提供する必要がある。このことは生産のリードタイムに対応する予測値の出力をも可能にするものである。

C及びDについては、対象とする製品の市場環境を巻き込んだ予測が必要であるということである。そのためには、市場の動きを表す指標の導入とその動特性の解析が前提であり、対象製品の動きとタイアップした市場全体の動きが予測機構に反映されている必要がある。また、市場の構造変化は単一の製品の販売動向からだけでは検出することは困難であり、上記の市場の構造変化が予測モデルに動的に影響可能な方式が要求される。

2. データマイニング

2.1. データマイニング

データマイニングについては確立された統一的な定義があるわけではない。しかしながら、一般的には「大規模なデータの集まりから、価値があり自明でない情報を効率的に発見することである」²⁾という程度において定義付けがなされている。すなわち、知識発見という考え方がその主流となっているものである。留意すべきは、データマイニングとは、統計的な仮説検定やすでに設定された仮説についての検証ではなくて「あるがままのデータからデータ間の新事実や関係の自動的な発見」ということである。

このような定義から考えれば、データマイニングはデータウェアハウスまたはそれに近い大規模で統一的な観点から蓄積されたデータの集合体をそのための前提としているものと考えられる。現在において紹介されているデータマイニング手法とその適用例を表1に示す。

表1においてはデータマイニングを実現するアルゴリズムとして各種統計理論、カーブ・フィッティング、回帰分析、時系列モデル、ニューラルネットワーク、遺伝アルゴリズムなどが挙げられている。このことは一見

データマイニング機能	アルゴリズム	適用例
相関	統計、集合論	市場バスケット分析
クラス分類	決定木、ニューラル・ネットワーク	ターゲット・マーケティング、品質管理、リスク評価
クラスタリング	ニューラル・ネットワーク、統計	市場セグメンテーション、設計再使用
モデル化	線形・非線型回帰、曲線近似、ニューラル・ネットワーク	顧客格付／得点付、価格モデル、プロセス制御
時系列予測	統計ARMAモデル、Box-Jenkins、ニューラル・ネットワーク	売上予測、金利予測、在庫管理
時系列パターン	統計、集合論	時系列市場バスケット分析

[表1. データマイニング機能 参照、参考文献2]

して、データマイニングが「統計的な仮説検定やすでに設定された仮説についての検証ではない」という定義に反すると考えられがちであるが、このことは「あるがままのデータからデータ間の新事実や関係の自動的な発見するために適用される手法」にすぎないということの意味するものである。すなわち、事前に設定された仮説がありそれを検証するという方法ではなく、データの集合体に対しての手法の適用により、そのなかに何らかの新事実・関係を発見するという立場に立つものである。

2.2. 需要予測におけるデータマイニング方式の採用


ここにおいて検討する需要予測はSCPにおける重要な要素として位置づけられるものであり、ERPにおいて定常的に行われる業務処理をビジネスモデルとして想定し、それを改善・改革する機能を有すべきものである。第1章において整理したA～Dまでの点については、前の2つが定常業務処理を前提とした予測方式であるのに対し、後の2点は

それまでのビジネスプロセスを変更するという特徴を有する。すなわち、刻々と蓄積されたデータウェアハウスに対し、そこからのデータによるデータマイニングの結果を反映させた予測方式の提案であり、これはオンライン処理という枠組みを前提としながらも、ビジネスプロセスの改変という特徴をもつものである。この様子を図示すると図2のように描かれるが、提案する方式は全体として逐次的なオンライン処理の中にあって、データマイニング処理とその結果を活用するというOLAP方式の姿を採るものである。

3. 需要予測方式への基本的要請

3.1. 逐次的オンライン処理側面からの要請

第1章におけるAとBの2点からは、本方式が基本的に逐次的オンライン処理を前提とすべきものであることが要請される。このことから、ここでは基本的なスキームとしてカルマンフィルタを採用する。カルマンフィルタはその背後に線形システム理論を前提とす



【図2. ビジネスプロセスの改変を意図した需要予測】

るが、逐次的なオンライン処理に対しては合理的な時系列推定・予測方式である。

また、Cの点については、予測方式においては多入力多出力が前提とされ、対象とする複数の変量が同時に予測可能性が保証されなければならない。

この要請はそのままカルマンフィルタの特徴につながるものである。カルマンフィルタの基本式は式(1)、(2)に記述されるように、複数の変量による状態ベクトルと観測ベクトルを前提としている。

$$\mathbf{x}_{k+1} = \Phi_{k+1,k}\mathbf{x}_k + \mathbf{C}_k\mathbf{u}_k + \mathbf{v}_k \quad (1)$$

$$\mathbf{y}_k = \mathbf{H}_k\mathbf{x}_k + \mathbf{w}_k \quad (2)$$

ここに、

\mathbf{x}_k : 状態ベクトル

$\Phi_{k+1,k}$: 状態遷移行列

\mathbf{C}_k : 制御行列

\mathbf{u}_k : 制御ベクトル

\mathbf{v}_k : 状態雑音ベクトル

\mathbf{y}_k : 観測ベクトル

\mathbf{H}_k : 観測行列

\mathbf{w}_k : 観測雑音ベクトル

状態雑音と観測雑音においては相互にまた、時点ごとに相関のない白色性の雑音を仮定する。

3.2. O L A P 处理的側面からの要請

ここでのO L A P 的处理の内容は第1章の要点Dに基づいた「予測処理の市場の構造変化への適応」ということに代表される。市場の構造変化はデータウェアハウスに蓄積されており、市場の時間的な構造変化を予測処理に反映させるためにデータマイニング処理を活用することを考える。

市場の構造変化の捉え方については様々なアプローチがある。通常、経営・経済時系列分析においては、その変動構造を論理的なモデルで記述することは不可能に近く、過去の時系列データからの回帰分析などの方法によ

り構造式を推定することが多く、結果としてその要素は定数であることから構造変化を取り込むことは困難である。


これらのことを考慮し、以前に我々はカルマンフィルタを予測の基本方式とした方式において、次のような構造変化の検出と反映の方法を提案した。

- (1) 状態空間をその更新時において、修正GMDH法により自己組織化する
- (2) 上記と同様な目的でニューロ回路網による自己組織化方法を採用する

上記の2つの方法に共通するものは、状態空間を対象とする予測対象の変数とその動きを説明する変数とによって構成し、それらの時系列の動きでもって市場動向を表現しようと考えたことである。したがって、この方法によれば状態空間の時間的な変化でもって市場の構造変化を表すことができ、カルマンフィルタにおける予測処理のサイクルにおいて市場の構造変化を反映させることができる。状態空間の時間的な変化はカルマンフィルタにおいては状態遷移行列の時間的な変化として表され、その方法として上記の(1)と(2)に示すように線形な相互作用に修正されたGMDHとニューロ回路網を適用した。この自己組織化方法により、それを施さない場合と比べ、かなりの予測精度の向上が見られた。

ここでは、状態空間の構成において、予測対象の変数の動きを説明する変数をそのまま導入せず、それらの主成分を代替させた。すなわち、市場動向を表現するものとして予測対象変数を説明する変数群の主成分を採用する。主成分の抽出におけるサンプルは過去の時系列データとし、取り上げる主成分の数は固有値の累積寄与率が80%程度を基準とする。この処理により、N個の時系列データがM(M<N)個の時系列データによって代表されることになり、もともとのN個の変数の

時間的変動がM個の時系列データの変動によって説明できることとなる。すなわち、個々の時系列の変動がそれらについての共通要素の変動によって説明されることにより、市場動向が浮き彫りにされることが予想される。その様子を図3に示す。



[図3. 時系列主成分の抽出]

4. 需要予測方式のスキーム

4.1. 全体構成

本需要予測システムの全体構成を図4にて示す。なお、入力される時系列については次の通りである。

- ・ {y} : 予測の対象とする変数の時系列
- ・ {x₁, x₂, ..., x_N} : 説明変数時系列

なお、これらは全て季節調整済みである。

4.2. 平滑化と基準化

入力される全ての変数についての季節調整済みの時系列に対して平滑化処理が施される。処理の内容は移動平均処理であり、この処理により不規則変動を取り除く。したがって、時系列がT (傾向変動), C (循環変動), S (季節変動), I (不規則変動) から構成されているとすれば、ここでの平滑化処理後の時系列はTC時系列となる。

平滑化後の全ての変数について、特定時点を基準として基準化する。基準化の方法は特定時点の値を基準としてそれ以外の時点の時系列の値を除するものである。この処理の後、各時系列については、不規則変動の分散をカルマンフィルタの観測雑音の分散と考える。すなわち、

説明変数時系列

$$\{x_{ij} : i=1, 2, \dots, n : j=1, 2, \dots, N\}$$

平滑化基準化後

$$\{x_{ij}^* : i=1, 2, \dots, n : j=1, 2, \dots, N\}$$

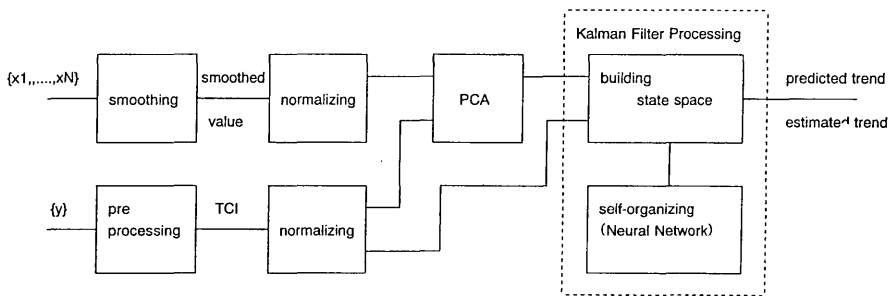
対象変数時系列 {y_i : i=1, 2, ..., n}

平滑化基準化後 {y_i^{*} : i=1, 2, ..., n}

と各々表記すれば、

$$\sigma_{wj}^2 = \sum_{i=1}^n (x_{ij} - x_{ij}^*)^2 / n \quad (j=1, 2, \dots, N) \tag{3}$$

[Total Prediction Process]



[図4. 全体構成図]

$$\sigma_w^2 = \sum_{i=1}^n (y_i - y_i^*)^2 / n \quad (4)$$

ここで、分散 $\sigma_{w_j}^2$ 、 σ_w^2 を各々、説明変数、対象変数についてのカルマンフィルタの観測雑音の分散として扱う。

4.3. 時系列主成分分析

時系列主成分分析は複数の時系列データをサンプルとして、統合化された相互に独立した変数の時系列を生成するものであり、ある時点における j 番目の主成分 p_j は次の式にて表される。

$$p_j = \sum_{k=1}^N f_{jk} x_k \quad (5)$$

ただし、

主成分個数 : $j = 1, 2, \dots, M$

変数個数 : $k = 1, 2, \dots, N$

ここに、

$$\sum_{k=1}^N f_{jk}^2 = 1 \quad (6)$$

$$\sum_{k=1}^N f_{ik} f_{jk} = 0 \quad (i \neq j) \quad (7)$$

主成分の数はその寄与率(固有値による累積値)でもって選択され、累積寄与率が80%程度の基準でもって選択される。すなわち、もともとの変数の変動の80%程度を説明できる数の主成分が固有値の大きい順に選択される。 f_{jk} は固有ベクトルであり、もともとの変数から主成分をそれらの一次結合により与えるものである。 f_{jk} は各時点において算出され、各々の時点において(5)により主成分 $\{p_j\}$ が生成されれば、時点全体として主成分の時系列が生成されることになる。

一般に、 M の数は N よりもかなり小さくなり、 $\{p_j : j = 1, 2, \dots, M\}$ はもともとの変数の変動の共通的な変動を表しているものと考えられ、このことから、主成分時系列は市場の共通変動(すなわち、市場の動き)相互に独立して表されていることと考えられる。すなわち、市場変動が抽出されたということと考えられる。なお、

主成分時系列

$$\{p_{ij} : i=1, 2, \dots, n; j=1, 2, \dots, M\}$$

と表し、平滑処理後のその時系列を

平滑化基準化後

$$\{p_{ij}^* : i=1, 2, \dots, n; j=1, 2, \dots, M\}$$

とあわせれば、主成分時系列の平滑値に対する分散は(8)式で表される。

$$\sigma_{w_j}^2 = \sum_{i=1}^n (p_{ij} - p_{ij}^*)^2 / n \quad (j=1, 2, \dots, M) \quad (8)$$

ここの分散 $\sigma_{w_j}^2$ 、 σ_w^2 が実質的にカルマンフィルタの観測雑音の分散として扱われる。

4.4. カルマンフィルタの構成

4.4.1. 観測値時系列

以上の前処理により、カルマンフィルタに投入する観測値の時系列は次のものである。

$$\{p_{ij} : i=1, 2, \dots, n; j=1, 2, \dots, M\}$$

$$\{y_i : i=1, 2, \dots, n\}$$

これらをまとめて

$$\{y_{ij} : i=1, 2, \dots, n; j=1, 2, \dots, m\}$$

$$(m=M+1)$$

とする。

4.4.2. カルマンフィルタのスキーム

カルマンフィルタの全体の流れを次のように示す。カルマンフィルタは入力された観測値をもとに最尤推定量を計算し、それに基づいて状態空間のダイナミクスを反映した予測値を算出するというプロセスを繰り返すものであり、次のstep 1 からstep 7 までの段階が各サイクルにおいて繰り返される。予測値はstep 3 にて、推定値はstep 6 にて出力される。

カルマンフィルタの処理サイクル

step 1 : 初期化

$k=0$ (サイクルの初期設定)

x_k^* (状態推定ベクトル) の初期化

$x_{k,k-1}$ (状態予測ベクトル) の初期化

$P_{k,k-1}$ (予測誤差共分散行列)の初期化

step2: 観測値入力

$$k = k + 1$$

y_k (観測値)の入力

step3: 予測値の計算

$$\mathbf{x}_{k,k-1} = \Phi_{k,k-1} \mathbf{x}_{k-1}^*$$

$$\mathbf{y}_{k,k-1} = \mathbf{H}_k \mathbf{x}_{k,k-1}$$

step4: ゲインの計算

$$\mathbf{B}_k = \mathbf{P}_{k,k-1} {}^t \mathbf{H}_k [\mathbf{H}_k \mathbf{P}_{k,k-1} {}^t \mathbf{H}_k + \mathbf{W}_k]^{-1}$$

(\mathbf{W}_k は観測誤差の共分散行列)

step5: 推定誤差共分散行列の計算

$$\begin{aligned} \mathbf{P}_{k,k} &= [\mathbf{I} - \mathbf{B}_k \mathbf{H}_k] \mathbf{P}_{k,k-1} \\ &\quad + \mathbf{B}_k \mathbf{W}_k {}^t \mathbf{B}_k \\ &= [\mathbf{P}_{k,k-1}^{-1} + {}^t \mathbf{H}_k \mathbf{W}_k^{-1} \mathbf{H}_k]^{-1} \end{aligned}$$

(\mathbf{I} は単位行列)

step6: 推定値の計算

$$\begin{aligned} \mathbf{x}_k^* &= \mathbf{x}_{k,k-1} + \mathbf{B}_k [\mathbf{y}_k - \mathbf{y}_{k,k-1}] \\ &= \mathbf{x}_{k,k-1} + \mathbf{B}_k [\mathbf{y}_k - \mathbf{H}_k \mathbf{x}_{k,k-1}] \\ \mathbf{y}_k^* &= \mathbf{H}_k \mathbf{x}_k^* \end{aligned}$$

step7: 予測誤差共分散行列の計算

$$\mathbf{P}_{k,k-1} = \Phi_{k,k-1} \mathbf{P}_{k,k-1} \Phi_{k,k-1} {}^t + \mathbf{V}_{k-1}$$

(\mathbf{V}_k は状態誤差の共分散行列)

step2:へ戻る

4.4.3. 状態遷移行列の可変性

カルマンフィルタを構成する場合に決め手となるものは状態遷移行列と観測行列の決定である。通常、物理系においてカルマンフィルタを構成する場合は、状態系のダイナミックス、観測系などが物理系の方程式群として表現され、それが状態遷移行列、観測行列の

記述となる。特に、状態遷移行列はある時点から次の時点への状態系の動的な振る舞いを記述するものであり、系の動的な推定の基本となるものである。一方、経済・経営系においては、一般的に対象とする系については動的な振る舞いを演繹的に記述することは不可能であり、状態変数についての得られた過去の時系列からの回帰的に推定するという方法に頼らざるを得ない。その場合は状態遷移行列の各要素は回帰係数(定数)となり、系の時間的な変化に対して対応できない。当然のことながら、遷移行列そのものの時間的な変化が保証されない場合は、カルマンフィルタはその理論的な枠組みから考えて、非定常な系に対しては適用できないこととなる。

ここでは、状態遷移行列の時間的な変化に対応する方法として時間的な推移による状態空間の自己組織化を導入する。すなわち、 $\Phi_{k,k-1}$ の各要素は状態変数各々およびそれら相互の時間的更新における自己組織化において与えられるという考えに基づく。以前には、自己組織化の方法として状態変数間の相互作用を線形に限定した修正されたGMDH法を導入したが、ここでは、非線形性を含むものとしてニューラルネットワークを適用する。ニューラルネットワークは階層型とし、過去の一定区間の隣接する時系列の組を教師用データとして学習させ、カルマンフィルタの更新時において最新の時点の状態変数の値を導入して予測を行わせるものである。すなわち、

状態遷移行列 $\Phi_{k+1,k}$ の生成に対して、教師用入出力を次のように設定する。

・教師用入力

$$\{\mathbf{x}_j; j = k - T, \dots, k - 1\} (T \text{は学習区間})$$


・教師用出力

$$\{\mathbf{x}_j; j = k - T + 1, \dots, k\} (T \text{は学習区間})$$

このようにして学習されたニューラルネット

ワークに対して $\{x_k\}$ を投入することにより $\{x_{k+1}\}$ が予測値として得られることになる。

【図5 状態遷移行列に対してのニューラルネットワークの適用】



この場合、状態遷移行列の対角要素は各変数についてのニューラルネットワークの出力値と入力値との比となり、非対角要素は0である。すなわち、

$$\Phi_{k,k-1} = \begin{pmatrix} x_{1k+1}/x_{1k} & 0 & 0 & \dots & 0 \\ 0 & x_{2k+1}/x_{2k} & & & \\ \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & \dots & \dots & x_{mk+1}/x_{mk} \end{pmatrix} \quad (9)$$

なお、観測行列は単位行列とする。これは観測行列が状態変数から観測変数への変換をあらわすものであり、ここでは状態変数と観測変数を同一のものとして扱うからである。しかしながら、カルマンフィルタのスキームから考えて、観測変換時には観測値には状態推定値に対して各々に観測雑音を加わる。

4.4.4. 状態雑音と観測雑音

カルマンフィルタの構成上において重要な働きをするものが状態、観測の各雑音である。これらの雑音の合理的な決定が適用の是非を決めるほど、その意味は大きい。状態雑音については(1)式から、それが状態更新を駆動するものであり、ここでは状態更新時における

予測誤差をもって与えることが合理的と考えられよう。したがって、ニューラルネットワークにおけるトレーニング時における収束誤差でもって与えることが出来る。観測雑音は観測変換時に真値に付加されるものであり、この合理的な与え方は経済・経営時系列の場合には困難であるが、4.2.節において述べた平滑化の誤差をそれに相当するものとして挙げる事が考えられる。

いずれの雑音においてもカルマンフィルタの構成においては、それら雑音の共分散行列のかたちで与えられる。

5. 事例検証

5.1. 事例について

本予測方式による検証の事例として、新車登録台数(月次時系列)を取り上げる。ここでは、トレンド中心時系列(TC系列)の予測に的を絞る、対象時系列は季節調整済みとする。データは1989年から1998年までの10年間、120サンプルである。

新車登録台数の説明変数として考えられる5つの変数を以下に挙げる。データの期間、サンプルサイズは同じであり、いずれも季節調整済みのものである。


- x_1 : 民間最終消費支出
- x_2 : 通貨供給量(M2 + CD)
- x_3 : 平均株価
- x_4 : 消費者物価指数
- x_5 : 建築着工面積

なお、対象時系列の新車登録台数は6番目の変数として定義する。


- x_6 : 新車登録台数

図6～図11に上記の各々の時系列の概形を示す。これらは全て1989年1月をもとに基準化された時系列である。


[図 6.
民間最終消費支出]




[図 7.
通貨供給量
(M2 + CD)]




[図 8. 平均株価]




[図9.
消費者物価指数]



[図10.
建築着工件数]



[図11.
新車登録台数]



5.2. 主成分時系列

前節に示した6つの時系列の主成分分析した結果の固有値と累積寄与率を次に示す。


	固有値	累積寄与率
第1主成分(p_1)	0.0550	0.8250
第2主成分(p_2)	0.0060	0.9180
第3主成分(p_3)	0.0040	0.9710
第4主成分(p_4)	0.0020	0.9950
第5主成分(p_5)	0.0004	0.9950
第6主成分(p_6)	0.0003	1.0000

これらの結果により、累積寄与率が97%の第3主成分まで取り上げる。主成分 $\{p_1, p_2, p_3\}$ の時系列を図12~図14に示す。なお、 $\{p_1, p_2, p_3\}$ の各々についての、 $\{x_1, x_2, x_3, x_4, x_5, x_6\}$ からの因子負荷量は次の通りであり、 $\{p_1, p_2, p_3\}$ を解釈するとすれば、次のように考えられよう。


	x_1	x_2	x_3	x_4	x_5	x_6
p_1	-0.0533	-0.0923	0.1874	-0.0385	0.0746	0.0427
p_2	0.0253	0.0405	0.0001	0.0077	0.0519	0.0347
p_3	0.0152	0.0335	0.0353	0.0507	-0.0287	-0.0085

- ・ p_1 : 全体の変動の83%を占めるものであり、特に $\{x_3\}$ による影響度が高い。上昇傾向の変数とは負の因子負荷量をもつ。「ビジネストレンド」と表現されよう。
- ・ p_2 : 全体変動の9%を占める。 $\{x_1, x_2, x_3\}$ の影響が大きい。「個人消費傾向」の意味合いをもつものと考えられよう。
- ・ p_3 : 全体変動の5%を占める。意味するものについては不明。


[図12.
第1主成分の
時系列]



[図13.
第2主成分の
時系列]



[図14.
第3主成分の
時系列]



5.3. カルマンフィルタの構成

本方式によるカルマンフィルタの構成は次の通りである。

・状態変数

第1主成分～第3主成分： $\{p_1, p_2, p_3\}$

新車登録台数： $\{x_6\}$

以上を基本時系列として、モデル化については次の3種の組合せを考える。

モデルA： $\{p_1, x_6\}$

モデルB： $\{p_1, p_2, x_6\}$

モデルC： $\{p_1, p_2, p_3, x_6\}$

・観測変数

状態変数と同じ

・状態遷移行列（初期設定区間）

初期設定区間（1989年～1985年）における行列要素の決定にはこの期間における回帰式を用いる。主成分に関しては、それらが各々独立であることを考慮して、一次の自己回帰モデルで記述する。

$$p_{1k} = -0.001 + 0.977p_{1k-1} \quad (10)$$

$$p_{2k} = 0.205 + 0.907p_{2k-2} \quad (11)$$

$$p_{3k} = 0.112 + 0.861p_{3k-3} \quad (12)$$

各モデルについて $\{x_6\}$ の初期設定の

回帰式は次の通りである。

$$\text{モデルA : } x_{6k} = 0.050 + 0.024p_{1k-1} + 0.942x_{6k-1} \quad (13)$$

$$\text{モデルB : } x_{6k} = 0.047 + 0.026p_{1k-1} + 0.008p_{2k-1} + 0.933x_{6k-1} \quad (14)$$

$$\text{モデルC : } x_{6k} = -0.040 + 0.027p_{1k-1} + 0.013p_{2k-1} + 0.054p_{3k-1} + 0.926x_{6k-1} \quad (15)$$

なお、予測期間（1996年～1998年）においては、過去3年間における時系列を学習データとしてニューラルネットワークを学習させ、それに最近時の観測値を投入することにより、予測値を求める。なお、各モデルについてのネットワークの構成は次の通りである。

モデルA：中間層 = 1，
中間層の個数 = 1

モデルB：中間層 = 1，
中間層の個数 = 2

モデルC：中間層 = 1，
中間層の個数 = 2

学習回数はいずれも8回であり、収束の程度は 10^{-3} である。

・観測行列

状態変数から観測変数への変換行列であり、定数項の列を除いて

モデルAについては、2行2列の単位行列

モデルBについては、3行3列の単位行列

モデルCについては、4行4列の単位行列

となる。

・状態雑音

初期設定区間においては、モデルA、B、Cに対応して、(13)、(14)、(15)の回帰式の平均2乗誤差で定義する。実際の値は次の通りである。

モデルA：0.000028

モデルB：0.000020

モデルC：0.000025

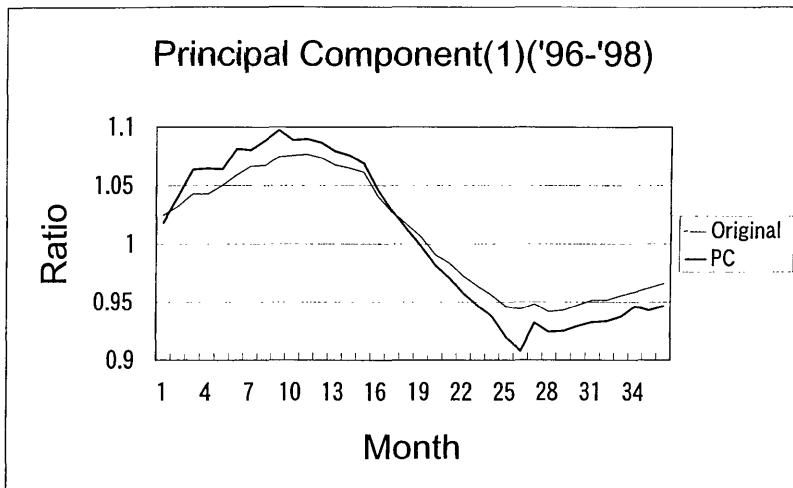
予測区間においては、ニューラルネットワーク学習における平均2乗誤差をあてる。

これは、予測のサイクルごとに計算され、更新される。


・観測雑音

$\{p_1, p_2, p_3, x_6\}$ の各々の移動平均


[図15. モデルAの予測値時系列]



[図16.
モデルBの
予測値時系列]



[図17.
モデルCの
予測値時系列]



(平均幅 = 3, 移動幅 = 1) についての平均 2 乗誤差で定義する。実際の値は次の通りである。

$$p_1 : 0.000233$$

$$p_2 : 0.000196$$

$$p_3 : 0.000166$$

$$x_6 : 0.000072$$

これらについては、初期設定区間及び予測期間の双方において利用する。

各モデルごとの評価の結果は他の方式と同時に表 2 に示す。なお各モデルにおける予測期間における予測値時系列と観測値時系列

を図15～図17に示す。

5.4. 他方式との比較

本方式の予測モデルの事例検証のために、いくつかの他の方式について結果の比較をおこなう。

5.4.1. ARモデル^{注3}

予測の対象となる新車登録台数の単一時系列についてのARモデルである。これについては、1989年から1998年までの10年間の時系列について、1階の差分を取り、定常化した

階差時系列についてARモデルを適用したものであり、次数はA I Cにより3が最適であった。モデル式は次の通りである。

$$Dx_{6k} = -0.3551Dx_{6k-1} - 0.1204Dx_{6k-2} - 0.4255Dx_{6k-3} \quad (16)$$

この場合、モデルの定義の期間に予測期間を含むので、結果は予測値ではなく推定値と考えられる。

5.4.2. 状態遷移行列要素が定数のカルマンフィルタ^{注3}


1989年～1998年までの10年間についての回

帰式により状態遷移行列の係数を決定したものである。この場合は状態遷移行列の各要素が定数となり、この区間内において定常カルマンフィルタとしての構成が可能となるが、予測期間をその中に含んでいるので、内挿的な予測としかかなりえない。

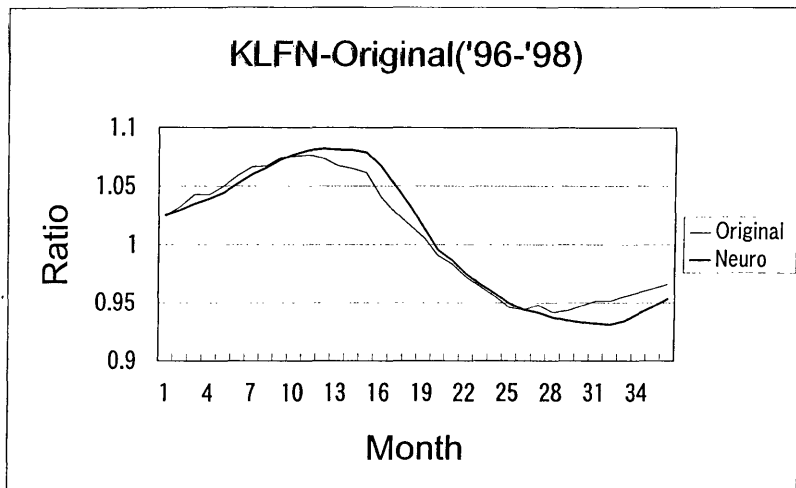
5.4.3. 状態遷移を自己組織化したカルマンフィルタ

4.4.3.の自己組織化の方法を線形に限定した修正GMDHおよびニューラルネットワークにより自己組織化をおこなったものである。

[図18. 修正GMDH自己組織化カルマンフィルタによる予測値時系列]



[図19. ニューラルネットワークによる自己組織化カルマンフィルタによる予測値時系列]



それ以外については本方式と同様である。前者は状態空間の更新において変数相互の線形関係のみしか取り込むことが出来ない。予測区間における結果の時系列を前者については図18、後者については図19に示す。

5.4.4. 予測精度の比較

以上取り上げた各方式、各モデルについて予測誤差の視点から比較を行ったものを表2と表3に示す。予測誤差は平均2乗誤差により計算される。なお、表3に表記する各方式の略記は次の通りである。

K L F - N : ニューラルネットワークを自己組織化に採用した方式

K L F - H : 修正GMDHを自己組織化に採用した方式

K L F - R : 自己組織化を採用しない方式 (定数係数)

A R (3) : 自己回帰モデル

表2と表3の結果より、次のことが判明する。

- ・状態空間の自己組織化の効果は大きい。
- ・K L F - Rに見受けられるように、状態遷移行列の決定のために予測期間を含めた期間を設定した場合においても、予測

精度においては、自己組織化した場合に劣る。

- ・自己組織化方法は修正GMDHよりもニューラルネットワークの方が精度が高い。

このことは、ニューラルネットワークが状態変数間の非線形の相互作用も繰り込んだ方法となっているからと考えられる。

- ・主成分時系列を抽出したモデルにおいては、2成分の場合が最も高精度となった。このことは、市場の共通変動要因を多くすればよいということにはならず、最適な市場変動要因が存在することを意味している。

6. おわりに

これまでに我々は状態空間に自己組織化法により時間的変化を与える需要予測方式を検討し、自己回帰法(スカラータイプ、ベクトルタイプ)に比較して良好な精度をあげられることを確認してきた。ここでは、状態空間を構成する変数を実変数から主成分に置き換え、複数の実変数から抽出された独立した共通変動を状態変数とする方式を試みた。第5章の結果から見て、この方式はいれまで試みた方法よりも一層の精度の向上が見受けら

[表2. 本方式の各モデルについての精度の比較]

モデル名	モデルA	モデルB	モデルC
予測誤差	0.000345	0.000098	0.000184
推定誤差	0.000017	0.000002	0.000008

[表3. 各方式についての精度の比較]

モデル名	K L F - N	K L F - H	K L F - R	A R (3)
予測誤差	0.000112	0.000128	0.000278	
推定誤差	0.000017	0.000018	0.000151	0.000233

れ、共通変動の抽出が有効であることの証明と考えられる。このことは抽出された主成分がおのおの独立した市場変動を表すものと考えられることから、複数の実変数による状態空間の構成より相互干渉のない変数でもって状態空間が構成されたことによるものと考えられる。これらのことを要約すれば、本方式については次のようにまとめられる。

- ・最初に取り上げる複数の変数が定まったものではなく任意性があり、主成分により共通的な市場変動を抽出できることから、データマイニング的な性格をもつ
- ・対象とする製品がおかれている市場の変動を相互干渉のない変数でもって抽出し、状態空間を構成することができる
- ・状態空間を構成する主成分数は最適なものが存在する。すなわち、少なすぎてもいけないが、多すぎると予測精度が低下する

特に最後の点については、主成分の固有値の大きさと累積寄与率によるその数の選択方法の研究が必要である。同時に、それらと関連する対象時系列の変動特性との関連についても検討が必要とされよう。

状態空間の自己組織化法についてはニューラルネットワークと修正GMDH法とを比較した場合、前者の方が精度上は効果が高いが、あまり大きな差はない。したがって、収束時間の早い線形に限定したGMDH法が利用性が高いという考えもできる。しかしながら、今日におけるコンピュータの処理速度の飛躍的な向上を考慮すれば、計算速度よりも精度上の向上要因がより重要であろう。

また、以上の検討を要すべき点に加えて、フィードバックを取り込んだニューラルネットワークの利用が考えられる。それについて

は、状態空間の遷移だけでなく、OLAP処理として単体での利用についての評価も行われるべきであろう。

注1. EPR推進フォーラム「ERP導入マネジメント」、IPA/INES, 1998, p.233参照。

注2. 参考文献2. p28参照。

注3. 参考文献10. 第4章参照。

参 考 文 献

1. 宮崎知明「SCMとOR」オペレーションズ・リサーチ, Vol.44, No.6, 1999.6
2. ジュゼフ・P. ビーガス著, (株)社会調査研究所, 日本IBM(株)訳「ニューラル・ネットワークによるデータマイニング」日経BP社, 1997
3. 喜連川優他「データウェアハウスとデータマイニング」オペレーションズ・リサーチ, Vol.43, No.12, 1998
4. 杉原敏夫「適応的モデルによる経済時系列分析」工学図書, 1996
5. 佐伯親良「最近の景気指標分析の展開」九州大学経済学会, 経済学研究, Vol.61, No.3-4, 1995
6. 松葉育雄「バックプロパゲーションによる特徴抽出」数理科学, Vol.338, 1991
7. H.Araki, T. Kimura, I.Arizona, H.Ohta "Demand Forecasting based on Differences of Demands via Neural Networks" J.JIMA, No.2, 1996
8. T.Sugihara, H.Tsubone "An Adaptive Demand Forecasting Approach for Supply Chain Management", Proc. 4-th. Inter Symp of Logistics, 1999. 7
9. T.Sugihara "Adaptive Demand Forecasting Approach Using Data Mining Technique", Proc. 5-th. Inter Symp of Logistics, 2000.7
10. 杉原敏夫「サプライチェーンマネジメントのためのOLAP需要予測」長崎大学経済学部研究年報, Vol.16, 2000.3