

重回帰分析以外で代表的な需要予測手法を以下に紹介します。

## 【ホルトウインターズ】

### 概要

当該モデルは、月次ベースのデータを対象とした超短期予測(1~6ヶ月先まで)モデルであり、時系列データを分解して捉えることに大きな特徴が見られる。アプローチに際しては、分割と成分の指数平滑化を繰返すことで推定値を求め、予測値を導出する仕組みになっている。

### 理論的背景

[計測モデル式]

$$y_t = (b_1 + b_2 t)ct + \varepsilon_t$$

$y_t$ : 売上高(時系列データ)

例) ある商品の販売量

$b_1$ : 水準値(定数項)

$b_2$ : 線形傾向成分

$c$ : 乗法的季節成分

$\varepsilon$ : 誤差項

$t$ : 時点( $t=1,2,3,\dots,T$ )

また、季節成分  $c_t$  は、期数  $L=12$ ヶ月を用いて、 $\sum_{t=1}^L c_t$  と定義されている。

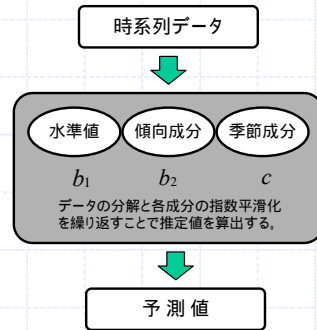
### 適用事例

月別機種別カラーテレビ販売台数の予測

月別ブランド別即席めん出荷量の予測

月別商品別化粧品出荷量の予測

24ヶ月以上の月別次データを有し季節性のあるもの



## 【Bassモデル】

### 概要

当該モデルは、主として反復購買を無視できるような耐久消費財の新製品を計測の対象としている。モデル化の背景には、伝染病学における病原菌の伝染モデルの特徴が新製品の普及プロセスに類似している点に発想の原点が見られる。一般に、耐久消費財の新製品が辿る普及動向は、いわゆるロジスティック型(S字曲線)で近似できることが経験的に立証されている。S字型では暗黙のうちに仮定されていた普及効果、つまり、先に新製品を購入した革新的採用者(innovator)が、追従者(imitator)に与える影響を明示的に取り入れたのがBassモデルである。

### 理論的背景

[計測モデル式]

$$\text{基本式: } A_t = P_t(K - N_t)$$

$$\Rightarrow A_t = \left( p + \frac{q}{K} N_t \right) (K - N_t) = pK + (q-p)N_t - \frac{q}{K} N_t^2$$

$A_t$ : 期間  $t$  の採用者数

$P_t$ : 期間  $t$  の採用者率

$K$ : 採用者数の上限(潜在採用者の全数)

$N_t$ : 期間  $t$  までの累積採用者数

$p$ : 革新的採用者の影響割合(イノベーション係数)

$q$ : 追従者の影響割合(イミテーション係数)

$$\text{実際の計測式: } A_t = a + bN_{t-1} + cN_{t-1}^2$$

### 適用事例

ハイビジョンテレビ中期需要予測

ワイドテレビ中期需要予測

反復購入を無視できる耐久消費財の新製品など

## 【ログロゲインバース曲線】

### 概要

ロジスティック曲線は普及率100%を上限として、そこへ低減的上昇率で接近するという特性をもつものであるが、ログロゲインバース曲線も上昇率は逓減し、ある時点で上限に達し、そこから絶対水準も低下するが、その低下率は上昇率より更に緩慢である場合に適合するモデルである。線形モデルでは急激な上昇や下降は説明できるが、緩やかな上昇や下降には適さない。当該モデルでは上限に達し緩やかに変化する場合に適している。

### 理論的背景

[計測モデル式]

$$\ln y_t = a + b \ln T + c \frac{1}{T}$$

$y_t$ : 売上高

例) ある商品の販売量

$\ln T$ : トレンドの対数

$1/T$ : トレンドの逆数

$T$ : トレンド ( $T = 1, 2, 3, \dots, n$ )

$a, b, c$ : 未知パラメータ

$t$ : 時点 ( $t = 1, 2, 3, \dots, n$ )

$n$ : データ期間数

### 適応事例

業務用カラーテレビの中期需要予測

日本酒課税移出数量の中期需要予測

需要の変化が上限に達し、緩やかに推移しているもの

## 【成長曲線: ゴンペルツ1次式】

### 概要

成長曲線はいわゆるS字型の曲線として知られており、製品やブランドのライフ・サイクルを分析する伝統的方法の一つである。成長曲線にも種々のものがあるが、本報告書の範囲内では、時間変数 $t$ を用いたゴンペルツ1次式を採用した。ゴンペルツ1次式の成長曲線は変曲点に対して非対称の成長を仮定している。

### 理論的背景

[計測モデル式]

$$\ln \left[ -\frac{1}{\ln(y_t / K)} \right] = a + bt + \varepsilon_t$$

$y_t$ : 期間 $t$ の普及率

例) ある商品の普及率

$t$ : 時点 ( $t = 1, 2, 3, \dots, T$ )

$K$ : 普及率の飽和水準

$\varepsilon_t$ : 誤差項

$a, b$ : 未知パラメータ

$\ln$ : 自然対数

### 適応事例

カラーテレビ2人以上世帯普及率の予測

総人口一人当たり即席めん出荷数量の予測

普及率や単位当たり需要量など

## 【予測値合成法】

### 概要

判断主導型予測や客観性主導型予測の方法は、企業の販売予測にそれなりの貢献を果たしているが、予測にはやはり誤差がつきまとう。予測誤差の観点から、その縮小を合理的に行う方法として、予測値合成(Combination forecasts)が実用面で注目されている。これは、オリジナルな予測の方法は別として、何種類かの予測値代替案を単純平均あるいは加重平均することにより導出される。代替案の中には、一見して使用上疑問が残る予測値が含まれていることもある。そのような結果は除外して残された予測結果を合成するのであるが、主観的アプローチに依存したものであっても対象になりうる点に使用上の柔軟性が見られる。

### 理論的背景

当該モデルは異なる複数の方法で算出された予測値を誤差の逆数をウェイトとして加重平均することで合成予測値を導出する。

### 【計測モデル式】

$$\hat{y}_t = \sum_{i=1}^N w_i \hat{y}_t^i \quad w_i = \frac{\sum_{j=1}^N \alpha_{ij}}{\sum_{i=1}^N \sum_{j=1}^N \alpha_{ij}}$$

ここに、

$\hat{y}_t^i$ : i番目の方法による予測値

$\alpha_{ij}$ : 誤差率に関する分散-共分散行列の逆行列の要素

$N$ : 予測手法の数

### 適応事例

プラスチック製品の需要予測

テレビ視聴率の短期予測

複数の手法による予測結果があるもの

## 【ベイジアン・コンセンサス】

### 概要

当該モデルは、複数の専門家から得られる予測情報を、グループメンバーのコンセンサス(consensus)が得られるように調整し、最終的に合成された単一の予測値を生成するアプローチである。このモデルは想定した専門家が保持している文脈情報の質によっ

て予測精度に差が生じると考えられている。

文脈情報とは、予測担当者としての専門家が保持している時系列的な見方や予測への経験以外の販売動向に対する説明、解釈、予期といった一連の予測を自己の判断の内 で組立てる際の広範な情報を指す。

### 理論的背景

【計測モデル式】...

$$\sigma^{*2} = \frac{1}{e^t \Sigma^{-1} e}$$

ここに、

$\mu$ : 専門家の予測に対する主観的判断分布の平均ベクトルで  $\mu = [\mu_1, \mu_2, \dots, \mu_k]^t$

$e$ : 単位ベクトルで  $e = [1, 1, \dots, 1]^t$

よって、式で与えられる平均値  $\mu^*$  が求める予測結果となる。コンセンサス分布の平均値  $\mu^*$  は、専門家の平均値の1次結合である。

$$\mu^* = \sum_{i=1}^k w_i \mu_i \quad \dots \quad w_i = \frac{\sum_{j=1}^k \alpha_{ij}}{\sum_{i=1}^k \sum_{j=1}^k \alpha_{ij}} \quad \dots$$

ただし、

$\Sigma^{-1} = \alpha_{ij}$  のとき、ウェイト  $w_i$  は、式に見る通りである。

ウェイト合計は1となるが、すべて正数とは限らない点に留意が必要。

$k$ : 専門家の数

### 適応事例

輸入ビールの短期需要予測

スナック菓子の新製品短期販売予測

複数の専門家の文脈情報等が活用できるもの

## 【最近隣(NN)モデル】

### 概要

最近隣モデル(nearest neighbor models:略してNNモデル)

とは、時系列データにおいて、ある時点のデータとそれに隣接する過去の一定期間に連続するデータ群とを対応付け、そのデータ群の類似しているものを採用してウエイト付けし、合成的予測値を導出するためのものである。

当該モデルは状態空間(state space)においてベクトルを形成しているラグ付きの時系列値を使用する。ベクトルは、時系列のアトラクターを再構築するのに必要となる。

予測は、アトラクターの周囲に存在するベクトルの歴史的道筋に基礎をおく。最近隣モデルの特徴は、伝統的な時系列モデルや回帰モデルに代表されるような関数関係をとらない点にある。代わりに、当該モデルは、時系列においてどんなアトラクターが作用しているのかを幾何学的に再現する。予測は、アトラクターが存在する適切な領域に焦点を合わせて実行される。NNモデルの基本的な発想は、右図に見るとおりである。

### 理論的背景

現在の状態  $y(t)$  と将来の未知の値  $y(t+T)$  は 印で、点線での円形内の 印は  $y(t)$  の近隣性を示している。短期的な予測を得るためには、領域内の近隣性を示すデータに着目し状態がその範囲内である遅れをもって時間発展すると考えるのである。いずれにしても、予測に有用と思われる望ましい1セットの近隣性を示すデータを如何に生成するかは重要であり、その単純な基準が距離の短さとなる。

### 適応事例

テレビ視聴率の短期予測

レストランにおける特定品目の短期売上予測

エアコンにおける特定機種短期販売予測

### 計算手順

以下、アプローチのステップを示す。

#### 【ステップ1】

分析、予測の対象となる時系列データを用意する。

#### 【ステップ2】

状態空間を作成する

#### 【ステップ3】

最新時点の状態空間ベクトルと、他の時点の状態空間ベクトルとの距離を導出する。

#### 【ステップ4】

ステップ3で導出した距離を短い順に並べ、最近隣からいずれの距離までを次ぎの時点の予測に採用するか意思決定を行う。

#### 【ステップ5】

採用する距離より、合成的予測のためのウエイトを導出する。

#### 【ステップ6】

ステップ5で求めたウエイトを用いて、合成予測値を導出する。




図. 予測における局所的近似の発想

(注)tは時点であり、円形内の黒丸印は、 $y(t)$ の近隣性を示す。