

状態空間モデルに基づく季節調整法における改良方法の提案：
 一般化 neg-log 変換の活用に基づくゼロ・負の値を含む時系列データの
 安定化と季節調整値の推定精度向上

高部 勲[†]

An improving method for seasonal adjustment methods by using a state space modeling
 -Stabilization of time series data including zero or negative values by using generalized neg-log
 transformation-

TAKABE Isao

X-12 ARIMA、DECOMP などの既存の季節調整法プログラムには、時系列の安定化による推定精度向上のために、対数変換や Box-Cox 変換等の各種の変換機能が搭載されている。しかし、ゼロや負の値を含む時系列データに対しては、これらの変換機能を適用することができない。そこで、ゼロや負の値を含むデータに対しても適用できる一般化 neg-log 変換を用いてデータを安定化させ、季節調整値の推定精度の向上を試みた。併せて季節調整プログラム DECOMP のモデルをベースとして Information Square Root Filter (ISRF) のアルゴリズムを適用し、計算精度の向上を図った。数値実験により、一般化 neg-log 変換を行うことで、季節調整系列を適切に捉えていることが示された。また、実データ（国内総生産・民間在庫品増加及び法人企業統計・在庫品増加）に対して提案手法を適用したところ、一般化 neg-log 変換を行うことで、AIC がある程度改善することが示された。

キーワード 季節調整、状態空間モデル、一般化 neg-log 変換、information square root filter

Various transformations such as logarithmic, Box-Cox transformation are installed in some seasonal adjustment methods including X-12 ARIMA, DECOMP in order to improve estimation accuracy by stabilizing time series. However, these functions cannot be applied to time series data including zero or negative values. In this paper, generalized neg-log transformation was used to improve the estimation accuracy of the seasonally adjusted value by stabilizing the data including zero and negative values. In addition, based on the program DECOMP, the Information Square Root Filter (ISRF) algorithm was applied to improve the calculation accuracy. Numerical experiments showed that seasonally adjusted series were properly captured by using generalized neg-log transformation and ISRF. Applying the proposed method to real data, it was shown that accuracy was improved from the viewpoint of AIC.

Key words : seasonal adjustment methods, state space model, generalized neg-log transformation,
 information square root filter

[†] 総務省統計局統計調査部経済基本構造統計課

はじめに

月次、四半期等の間隔で提供される時系列データから、季節的な変動を取り除き、時系列データの傾向などを適切に把握するために、各種の季節調整法が用いられている。我が国では従前から、アメリカセンサス局が開発した季節調整法 X-12 ARIMA が用いられている。一方で、近年、欧州を中心に、スペイン銀行が開発した TRAMO-SEATS という、ウィナー・コルモゴロフフィルタ (Wiener-Kolmogorov filter) に基づく季節調整法も、用いられるようになってきている (UNECE (2012))。これらの季節調整法の詳細については、高岡 (2016)、高部 (2009) などを参照。また、このような状況で、アメリカセンサス局では X-13 ARIMA-SEATS と呼ばれるプログラムを新たに開発しており、同プログラムでは、スペックファイルを詳細に設定することで、さまざまなモデルやパラメータを設定し、X-12ARIMA 及び TRAMO-SEATS のそれぞれの季節調整法を選択して、各種の時系列データの特徴に合わせた形で適用できるようになっている (野木森 (2013))。我が国では、統計数理研究所により、DECOMP という、状態空間モデルに基づく季節調整法が開発されており (北川 (1997)、Kitagawa & Gerch (1994)、Kitagawa & Gersch (1996))、特別なプログラムを PC にインストールする必要なく、ウェブから簡易な操作で扱うことのできる Web Decomp というプログラムも提供されている (佐藤 (1997))。また、R 上で操作できる timsac パッケージにおいても、DECOMP の機能が提供されている (統計数理研究所 (2016))。

ところで、これらの各種の季節調整法は、時系列データが安定的に推移していることを前提としており、異常値やレベルシフト、期中での急激な周波数の変化等を含む時系列データに対しては、そのままでは適用できない。そこで、このような場合に、時系列データの変動を安定化させるために、事前に回帰モデルや時系列の変換により、それらの変動を取り除く場合がある。このような時系列データの事前調整を支援するため、X-12 ARIMA、TRAMO-SEATS など既存の季節調整プログラムには、平方根変換、対数変換、べき乗変換、Box-Cox 変換等を含む様々なデータ変換の機能が、オプションとして搭載されている。しかし、これらの変換には、対数や平方根などの計算が含まれており、分析対象の数値が正値であることを前提としていることから、ゼロや負の値を含むデータには適用することができないという欠点がある (奥本 (2000))。そこで本稿では、主にファイナンス・信用リスク分析の分野で用いられ、ゼロや負の値を含むデータにも適用できる一般化 neg-log 変換を用いて、時系列データの安定化と、季節調整値の推定精度向上を図った。

以下、本稿の構成について述べる。第 1 章では、本研究の目的について述べるとともに、時系列データの安定化を図るための各種の変換手法について紹介する。第 2 章では、本稿において主要なツールとして用いる状態空間モデルに基づく季節調整法について紹介するとともに、本稿で新たに提案する、時系列の安定化を組み込んだ季節調整法について説明する。併せて Information Square Root Filter (ISRf) のアルゴリズム (Kaminski et al. (1971)) に基づく、より効率的かつ推定精度の高い、状態空間モデルの計算手法について解説する。第 3 章では、人工的に作成したデータに基づく数値実験の結果について紹介し、本稿で提案する手法が既存の方法よりも優れていることを示す。第 4 章では、提案手法を 2 種類の実データに対して適用した結果について示すとともに、提案手法が季節調整後の時系列の安定化を実現している点について説明する。また併せて、X-12 ARIMA に搭載されている sliding span analysis (国友編 (2004)) の手法を適用することにより、一般化 neg-log 変換のチューニングパラメータ λ の時系列的な変化・安定性を分析した結果について説明する。最後に、推定結果のまとめと今後の課題について説明する。

1 本研究の目的と各種変換手法の紹介

この章では、時系列データを含む各種データの安定化に用いられる様々な変換手法について説明するとともに、本稿において中心的な役割を果たす変換手法である `neg-log` 変換及び一般化 `neg-log` 変換について説明する。

1.1 季節調整法における時系列データの安定化

X-12 ARIMA、TRAMO-SEATS、DECOMP などの季節調整法では、時系列データの安定的な推移を前提としており、異常値やレベルシフトなどを含む時系列に対しては、データを安定化させるために、事前に回帰モデルや時系列の変換によって、それらの変動を取り除く場合がある。既存の季節調整法のプログラムでは、時系列の安定化・推定精度向上のために、平方根変換や対数変換、べき乗変換、Box-Cox 変換を含む様々な変換機能がオプションとして搭載されている。官庁統計に対する季節調整の際に従前から広く用いられている季節調整法 X-12 ARIMA における変数変換のための関数や適用事例については、国友(2001)、国友(2004)、有田(2012)などが詳しい。主要な季節調整法 (X-12 ARIMA、TRAMO-SEATS 及び DECOMP) において使用が可能なデータ変換の手法を示したものが、以下の表 1 である。

表 1 主要な季節調整法で適用することのできる変換手法

季節調整法	適用できる変換手法
X-12 ARIMA	BOX-COX 変換、対数変換、平方根変換、べき乗変換、ロジスティック変換 等
TRAMO-SEATS	BOX-COX 変換、対数変換、平方根変換、べき乗変換 等
DECOMP	対数変換

上記の季節調整法のうち、X-12 ARIMA については、スペックファイル (プログラムを動かすための各種の指示が書かれたファイル) において、`transform` コマンドを使用することにより、様々な変換方法 (対数変換、平方変換、BOX-COX 変換、ロジスティック変換等) を指定することができる。また、TRAMO-SEATS については、`Data Transformation` コマンドを用いることで、ARIMA モデルに基づく各種変動の推計を行う際に、変数変換の適用の有無と適用方法の詳細について、設定することができる。次節では、これらの変換手法の内容について説明する。

1.2 正の数値に対して用いられるデータの安定化のための変換手法

時系列データの安定化のために用いられる変換には、前節でも紹介したとおり、様々な手法がある。以下では、これらの様々な変換手法について、特に正の値をとるデータに対して用いられる変換手法について、説明する。

(1) 対数変換

対数変換は、以下のとおり、時系列データの対数をとる変換である。

$$Y_n = \log(X_n)$$

対数の底に用いる数値は、正值であれば任意の値でよいが、一般にネイピア数 ($e=2.71828\cdots$) が用いられることが多い。数値の大まかな桁の感覚をつかみたい場合には、底として 10 が用いられる場合もある。

平均値の上昇とともに変動が大きくなるような時系列データについては、対数変換によって変動を安定化させることができる。これは、対数変換したデータから計算した標準偏差が、変動係数とほぼ等しいことによる。このことは、以下の式変形からも理解できる。

$$\begin{aligned} \log(X_i) &= \log(\bar{X}) + \log\{1 + (X_i - \bar{X})/\bar{X}\} \\ &\approx \log(\bar{X}) + 1 + (X_i - \bar{X})/\bar{X} \end{aligned}$$

また、対数変換には、分布の歪みを補正する効果が備わっていることから、例えば、世帯の貯蓄や企業の財務・経理情報など、極端に歪んでいる分布の変動を抑える目的で、よく利用されている。

(2) 平方根変換

平方根変換は、以下のとおり、時系列データの平方根をとる変換である。

$$Y_n = \sqrt{X_n}$$

平方根変換は、対数変換と似た効果を持つ変換であるが、対数変換よりも。データの変動の圧縮が緩やかであるという特徴を持つ。

(3) Box-Cox 変換

Box-Cox 変換は、対数変換と似ているが、分布の形状を操作するチューニングパラメータ (λ) を導入することで、対数変換よりも柔軟な変換を行うことができる。Box-Cox 変換は、対数変換と変換なしの中間の状態を表現できる変換である。変換の式は、以下のとおりである。

$$\begin{aligned} Y_n &= (X_n^\lambda - 1)/\lambda & (\lambda \neq 0) \\ &= \ln(X_n) & (\lambda = 0) \end{aligned}$$

Box-Cox 変換において、 $\lambda = 1$ とすると、恒等変換（何も変換しない）とほぼ同等の操作となる（操作は -1 のみ）。また、 $\lambda = 0$ とすると、対数変換となる（このことは、ロピタルの定理により容易に証明可能である。）。適切なチューニングパラメータ λ の値は、データから最尤法によって求めることもできる。データに合わせて、 λ の値を適切にチューニングすることで、データを安定化するための様々な変換を実現することができる。

(4) ロジスティック変換

ロジスティック変換は、以下の式で定義される変換である（松本ほか (2010)）。結果数値が 0 から 1 の間になるように変換する必要がある場合などに用いられる。

$$Y_n = \exp(X_n)/(1 + \exp(X_n))$$

1.3 ゼロや負の値にも適用できるデータの安定化のための変換手法

1.2 節で紹介した様々な変換手法は、式の中に対数や平方根が含まれており、対象となるデータが正値をとることを前提としている。よって、データがゼロや負の値をとる場合には、これらの変換を適用することはできない。例えば、国内総生産における民間在庫品増加や法人企業統計における在庫品増加などの時系列では、ゼロや負の値が生じることから、これらの変換手法が使用できないということが、指摘されている（奥本(2000)）。そこで、これまでに紹介した変換手法を改良することで、ゼロや負の値をとるデータについても安定化することのできる変換手法がある。以下では、ゼロや負の値をとるデータにも適用可能な変換手法変換を3つ、紹介する。

(1) neg-log 変換

neg-log 変換(negative logarithmic transformation)（「ネグログ」変換と発音する。）は、ゼロや負の値も含むデータについて、安定化を行うための変換である。neg-log 変換は、主にファイナンスや信用リスク分析の分野で、多く用いられてきている。例えば、金融・財務指標を用いた企業のデフォルト確率・倒産確率の推定を行う場合に、説明変数として用いられる金融・財務指標の中には、利益や負債のように、ゼロやマイナスの値をとるものや、分布が左右に極端に歪んでいるものが存在する。そのような場合に、変数の変動を安定化させて、外れ値の影響を緩和させた形で、効果的なロジットモデルの推定を行うために、neg-log 変換が広く用いられている（山下(2011)、森平(2009)など）。neg-log 変換の式の形状は、以下のとおりである。

$$Y_n = \text{sgn}(X_n) \times \ln(|X_n| + 1)$$

ここで $\text{sgn}(X_n)$ は X_n の符号を表しており、これは X_n が正の場合は1を、負の場合は-1をとる関数である ($|X_n|$ は X_n の絶対値を表している。 $\text{sgn}(X_n) \cdot |X_n| = X_n$)。neg-log 変換は、対数変換から、対数の中の符号 $\text{sgn}(X_n)$ の部分だけを外に取り出した形になっている。neg-log 変換により、変数の符号に関係なく、対数変換のように、ゼロの近辺の値は拡大され、ゼロから離れた値は縮小されることとなり、最終的には時系列の極端な変動が緩和され、データの安定化を実現することができる。ただし、この変換は、Box-Cox 変換のように、分布の形状を操作・調節するためのチューニングパラメータを持っていないため、データに合わせた柔軟な変換を行うことができないというデメリットがある。このようなチューニングパラメータを持つ変換として、次節で紹介する一般化 neg-log 変換が用いられている。

(2) 一般化 neg-log 変換

neg-log 変換は、チューニングパラメータを持っておらず、データの内容や分布の歪みの程度に応じて、変換の形状を柔軟に変化させるといった調節を行うことができない。そこで、前述の BOX-COX 変換を発展させた、以下の一般化 neg-log 変換が考案されている（John & Draper(1980)）。

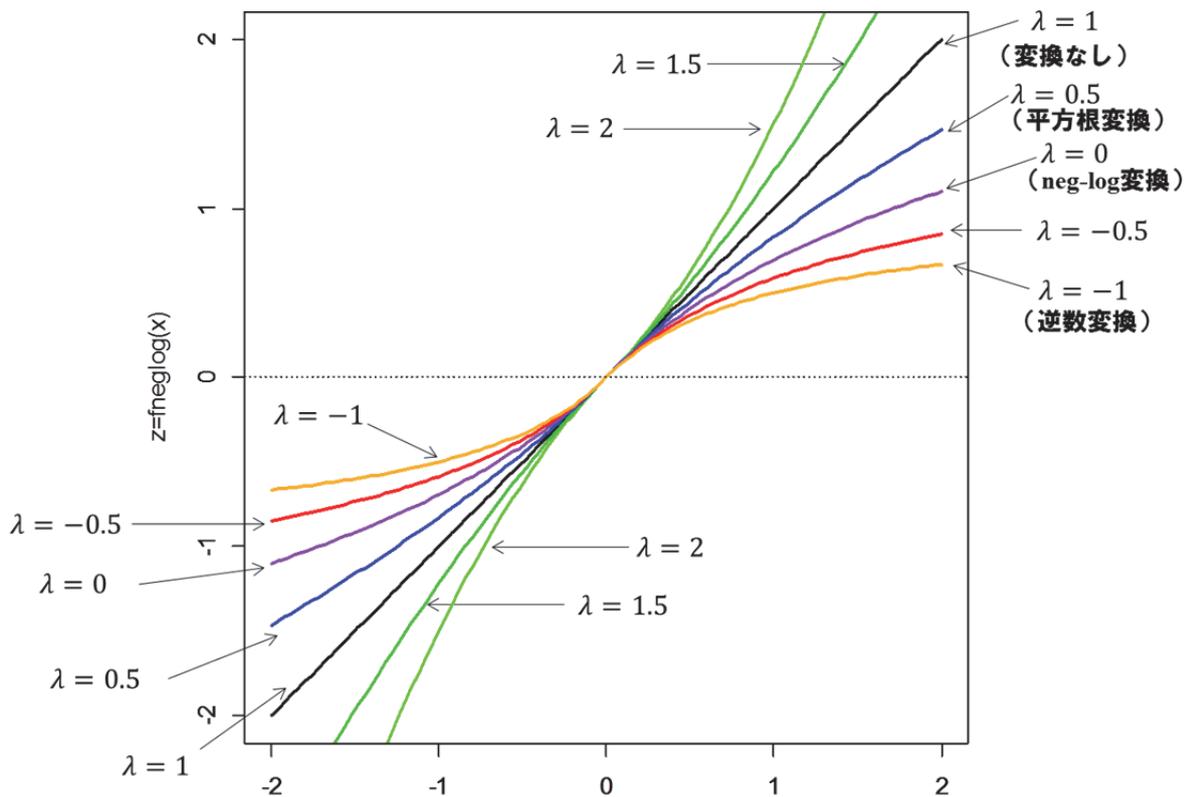
$$\begin{aligned} Y_n &= \text{sgn}(X_n) \times \{(|X_n| + 1)^\lambda - 1\} / \lambda \quad (\lambda \neq 0) \\ &= \text{sgn}(X_n) \times \ln(|X_n| + 1) \quad (\lambda = 0) \end{aligned}$$

一般化 neg-log 変換は、Box-Cox 変換を負の値に拡張した変換である。高橋(2015)では、実際の金融データ（CRD データ）に対して、一般化 neg-log 変換を適用し、データの安定化を行

った上で、企業のデフォルト確率を、ロジットモデルにより推定している。その結果、他の様々な外れ値処理の手法と比較して、データがより安定的になり、結果精度が向上したということが示されている。

一般化 neg-log 変換において、チューニングパラメータ λ を様々に変化させた場合の変換後のデータの形状を示したものが、以下の図 1 である。この図において、正の領域に限定すれば、これまでに紹介した他の変換（対数変換、平方根変換等）も含むグラフとなっている。また、正の領域のグラフを、原点に対して点対称に写したものが、負の領域のグラフとなっている。一般化 neg-log 変換には、グラフの形状から、ゼロに近い値を拡大し、ゼロから離れた値を縮小させる効果があることがわかる。

図 1 一般化 neg-log 変換のグラフ



(3) Yeo-Johnson 変換

時系列を安定化させる別の変換として、Yeo-Johnson 変換がある (Yeo & Johnson (1998))。さきほどの説明では、対数変換等の正の領域のグラフを原点に対して点対称に写したものが一般化 neg-log 変換であった。これに対して Yeo-Johnson 変換は、対数変換等の正の領域のグラフを、 $Y = -X$ という直線に関して線対称に写したものである。Yeo-Johnson 変換は主に、データの分布を正規分布の形状に近づけるために用いられる。Yeo-Johnson 変換の式を、以下のとおりである。

$$\begin{aligned}
 \psi(\lambda, x) &= \{(x + 1)^\lambda - 1\} / \lambda && (x \geq 0, \lambda \neq 0) \\
 &= \log(x + 1) && (x \geq 0, \lambda = 0) \\
 &= -\{(-x + 1)^{2-\lambda} - 1\} / (2 - \lambda) && (x < 0, \lambda \neq 2) \\
 &= -\log(-x + 1) && (x < 0, \lambda = 2)
 \end{aligned}$$

Yeo-Johnson 変換は、一般化 neg-log 変換とは異なる形で、Box-Cox 変換を負の値に拡張した変換である。ファイナンスのデータに対して Yeo-Johnson 変換を適用して時系列の安定化を行っている研究事例としては、田上・山下 (2015) がある。同論文では、デフォルト企業の正常復帰に関する要因分析と正常復帰確率推定モデルにおいて、説明変数の説明力を向上させるために、Yeo-Johnson 変換を施した変数についても説明変数として分析に用いており、データの分布の歪みを補正し、異常値を丸め込むことで、結果として、モデルの説明力の向上があったと報告されている。なお、本稿の分析では一般化 neg-log 変換のみを分析の対象としており、Yeo-Johnson 変換は用いていないが、変動を抑える新たな変換方法として、試してみる余地はあると思われる。

2 状態空間モデルに基づく季節調整法及び新たに提案する手法

2.1 状態空間モデルに基づく季節調整法

本稿では、変換の有無についての比較を行いやすくするために、一貫して、状態空間モデルに基づく季節調整法を考えることとする (片山 (2000)、片山 (2011))。状態空間モデルに基づく季節調整法を用いることで、モデルの当てはまりの程度について、AIC を用いて判断することが可能となる。また計算の際には Information square root filter のように、計算精度の高い効率的な計算手法を適用できるメリットがある。状態空間モデルは、観測方程式及び状態方程式からなるモデルであり、様々な時系列モデルを各種の「状態」(トレンド、季節性等)に分解した、柔軟な形式で表現することができる。

ここで、今後の分析においてベースとなるモデルとして、DECOMP で用いられているモデルを簡略化した、以下の状態空間モデルを設定する。なお、以下のモデルでは、時系列の周期として、四半期を想定しているが、月次に変更することも可能である。DECOMP の詳細については、北川(1997)を参照。

(1) 観測方程式 (Measurement Equation)

$$X_n = T_n + S_n + I_n \quad I_n \sim N(0, \sigma^2)$$

(2) 状態 (遷移) 方程式 (State (Transition) Equation)

$$T_n = T_{n-1} + v_{1n} \quad v_{1n} \sim N(0, \tau_1^2)$$

$$S_n = -S_{n-1} - \dots - S_{n-3} + v_{2n} \quad v_{2n} \sim N(0, \tau_2^2)$$

(X_n : 観測値 T_n : トレンド S_n : 季節性 I_n : 不規則変動)

このモデルは、Decomp において設定することができる各種の季節調整モデルの中でも、最も簡易なモデルとなっている。状態空間モデルは、上記のモデル以外にも、例えば AR (Autoregressive) モデルにより表現されるような短期的な循環変動や、回帰モデルで表現されるような曜日効果などの要素についても、モデルに含めることができる。本稿では、一般化 neg-log 変換による時系列の安定化が季節調整結果に与える影響を見ることに焦点を当てているため、複雑なモデルを考えることはせずに、上記の簡易なモデルを採用している。

以上の状態空間モデルを行列形式で表現すると、以下のようになる。このように、行列の形式でモデルを表現することができれば、後述する Information square root filter の公式に当てはめ

ることにより、状態の推定値を簡単に求めることができる。

[状態方程式]

$$X_n = F_n X_{n-1} + G_n v_n \quad v_{2n} = [v_{1n} \quad v_{2n}]^T \quad v_{1n} \sim N(0, \tau_1^2) \quad v_{2n} \sim N(0, \tau_2^2)$$

[観測方程式]

$$Y_n = H_n X_n + w_n \quad w_n \sim N(0, \sigma^2)$$

$$X_n = [T_n \quad S_n \quad S_{n-1} \quad S_{n-2}]^T : \text{状態ベクトル}$$

$$F_n = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & -1 & -1 & -1 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \quad G_n = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad H_n = [1 \quad 1 \quad 0 \quad 0]$$

2.2 Information Square Root Filter に基づく最適値の推定

状態空間モデルで表現が得られた場合、その最適な推定値は、カルマンフィルタ (Kalman Filter) と呼ばれる効率的なアルゴリズムで推定することができる (北川 (2005))。ただし、通常のカルマンフィルタでは、行列の計算を連続的に行っていく際に、状態ベクトルの分散共分散行列の推定値が正値対称行列ではなくなる可能性や、計算の効率が悪く計算精度が低下する可能性について指摘されている (Kitagawa & Gersh (1996))。このような問題に対しては、行列を平方根変換して計算を安定化させる手法を用いることで、対応できると考えられる。

本稿では、カルマンフィルタではなく、DECOMP における数値計算で採用されている Information Square Root Filter(ISRF)を適用することで、より計算精度の高い推定を行う。Kitagawa & Gersh (1996) によれば、Information Square Root Filter を活用することで、季節調整モデルのように非定常成分を含む曖昧な事前分布から出発した場合に生ずる数値的不安定性を解消 (分散無限大の初期状態を実現。) できるとされており、また、最小二乗法におけるハウスホルダー法 (Householder Transformation Method) に相当する平方根アルゴリズムが用いられていることから、通常のカルマンフィルタと比較して、2倍の計算精度を実現できるとされている。以下では、Information Square Root Filter の具体的な計算アルゴリズムを示す。なおここで、

$V_{n|n-1} = R_n^{-T} R_n^{-1}$ 、 $V_{n|n} = S_n^{-T} S_n^{-1}$ としている。また変換行列 P は、適当なハウスホルダー (上三角化) 変換に対応する行列を表している。Information Square Root Filter の理論面での説明や計算アルゴリズムの導出については、Kaminski et al.(1971)が詳しい。ハウスホルダー変換とその最小二乗法への応用については、森 (1987) を参照。

[Information Square Root Filter のアルゴリズム]

(1) 一期先予測

$$\begin{bmatrix} W_n & T_n & a_n \\ 0 & R_n^{-1} & b_n \end{bmatrix} = P \begin{bmatrix} U_n^{-1} & 0 & 0 \\ -S_{n-1}^{-1} F_n^{-1} G_n & S_{n-1}^{-1} F_n^{-1} & c_{n-1} \end{bmatrix}, \quad U_n^{-1} = \begin{bmatrix} \tau_1^{-1} & 0 \\ 0 & \tau_2^{-1} \end{bmatrix}, \quad x_{n|n-1} = R_n b_n$$

(2) フィルタ

$$\begin{bmatrix} S_n^{-1} & c_n \\ 0 & e_n \end{bmatrix} = P \begin{bmatrix} R_n^{-1} & b_n \\ \sigma^{-1}H_n & \sigma^{-1}Y_n \end{bmatrix}, \quad x_{n|n} = S_n c_n$$

(3) 平滑化

$$X_{N|N} = S_N c_N$$

$$v_{n-1|N} = W_n^{-1}(a_n - T_n X_{n|N})$$

$$X_{n-1|N} = F_n^{-1}(X_{n|N} - G_n v_{n-1|N})$$

2.3 新たに提案する手法

ここでは、本稿で提案する手法について、説明する。

(1) まず、ゼロや負の値を含む時系列データに対して、一般化 **neg-log** 変換を適用し、データの変動を抑えることで、安定化を図る。

(2) 次に、一般化 **neg-log** 変換を適用した後の時系列データに対して、2.1 節で示した状態空間モデルを当てはめて推定を行い、元の時系列データをトレンド、季節性、不規則変動の各成分に分解する。このようにして分解した系列から、季節性の推定値を除去することで、一般化 **neg-log** 変換適用後の時系列に対する季節調整値とする。

〔※このときに、**Information Square Root Filter** アルゴリズムを適用することで、計算精度の向上を図る。〕

(3) 最後に、このようにして得られた季節調整結果に対して、一般化 **neg-log** 変換の逆変換を適用することで、データのスケールを元に戻す。こうして得られた最終的な系列を、提案手法による季節調整済み系列とする。

上記の状態空間モデルにおいて、推定すべきハイパーパラメータは、 σ^2 、 τ_1^2 、 τ_2^2 の3つであるが、計算上の工夫 ($\sigma^2 = 1$ と置く) を行うことで、数値計算を行う必要のあるパラメータを1つだけ (観測ノイズの分散 σ^2) 減らすことができるので、合計で2つのハイパーパラメータ (τ_1^2/σ^2 、 τ_2^2/σ^2) について、一期先予測誤差 $(y_n - x_{n|n-1})^2 / (H_n^T V_{n|n-1} H_n + 1)$ を基に最尤推定を行えばよい (北川 (2005))。ここで、本稿における数値計算のプログラミングは全てRで行った。また、最尤法によりハイパーパラメータを推定する際の、尤度関数の非線形最適化の計算については、Rの非線形最適化関数 **optim** を利用し、**BFGS** 法に基づく準ニュートン法を適用した。計算の詳細については、付録のプログラムを参照。**BFGS** 法・準ニュートン法については、福島 (2011)、今野・山下 (1978) を参照。

これまでに述べてきた、変数変換及び **Information Square Root Filter** に基づく提案手法の季節調整法のアルゴリズムについて、改めて、以下のとおりまとめておく。

【Step 1】 ゼロ・負の値を含む原系列に対して一般化 neg-log 変換を適用。

$$Z_n = f_{neg-log}(Y_n)$$

【Step 2】 変換後の系列から Information Square Root Filter アルゴリズムにより、暫定的な季節調整済系列 \widehat{A}_n を推定。

$$\begin{aligned} Z_n &= T_n + S_n + I_n \\ \widehat{A}_n &= Z_n - \widehat{S}_n \end{aligned}$$

【Step 3】 上記の暫定季節調整済系列 \widehat{A}_n に一般化 neg-log「逆」変換を適用して最終季節調整済系列 \widehat{A}_n を推定。

$$\widehat{A}_n = f_{neg-log}^{-1}(\widehat{A}_n)$$

2.4 チューニングパラメータ λ の推定

提案手法の計算に当っては、あらかじめ、チューニングパラメータ λ を設定しておく必要がある。 λ の値については、観測データから、最尤法により決定することができる。本稿では、イメージをつかみやすくするために、AIC を最小化するパラメータを推定する。これについては、数値的最適化により計算を行う。このようにして、AIC を最小とする λ を事前に推定した上で、その λ を基に一般化 neg-log 変換を行って時系列データを安定化し、提案手法に基づく季節調整法を適用する。

2.5 初期分布の推定

状態空間モデルの推定を行う際には、状態ベクトルの初期分布（状態ベクトルの平均とその分散共分散行列）を設定する必要がある。初期分布の影響を少なくするために、 τ_0^2 を非常に大きな値とし、 I_d を d 次元の単位行列として、 $\tau_0^2 I_d$ を分散共分散行列として用いる方法がある。ただしこの方法では、 τ_0^2 の設定の仕方によって、尤度や状態などの計算結果に影響を与える可能性がある。本稿では、北川（1997）の方法をベースに、時間を逆転した時系列データを用いることで、状態ベクトルの初期分布の計算と、その後の状態の推定を行っている。

ここで、対象となる時系列データを、 $\{Y_1, Y_2, \dots, Y_n\}$ とする。このとき、2.4 節の Step 2 における状態の推定を、以下のように行う。

【Step 2-1】 時間を逆転させた時系列データ $\{Y_n, Y_{n-1}, \dots, Y_1\}$ に対して Information Square Root Filter アルゴリズムを適用することで、第 1 期の状態ベクトルの平均値の推定値 $\widehat{X}_1 = [\widehat{T}_1 \ \widehat{S}_1 \ \widehat{S}_2 \ \widehat{S}_3]^T$ を計算する（※時間が逆転していることに注意。）と、状態ベクトルの分散共分散行列 S^{-1} を推定する（※今回使用したモデルでは、分散共分散行列は定常となり、時点によらず一定となることから、添字を削除している。）。

【Step 2-2】 Step 1 で計算した \widehat{X}_1 をベースに、1 期先から 3 期先までの予測を計算することにより、以下の状態の予測値を得る（※時間が逆転していることに注意。）。

- 1期先予測： $\hat{X}_0 = [\hat{T}_0 \ \hat{S}_0 \ \hat{S}_1 \ \hat{S}_2]^T$
- 2期先予測： $\hat{X}_{-1} = [\hat{T}_{-1} \ \hat{S}_{-1} \ \hat{S}_0 \ \hat{S}_1]^T$
- 3期先予測： $\hat{X}_{-2} = [\hat{T}_{-2} \ \hat{S}_{-2} \ \hat{S}_{-1} \ \hat{S}_0]^T$

これらの推定値を基に、初期状態 $\bar{X}_0 = [\hat{T}_0 \ \hat{S}_0 \ \hat{S}_{-1} \ \hat{S}_{-2}]^T$ を構成する。

【Step 2-3】 Step 1 及び Step 2 において設定した初期状態ベクトルの分布 (\bar{X}_0, S^{-1}) を基に、元の時系列データ $\{Y_1, Y_2, \dots, Y_n\}$ に対して Information Square Root Filter アルゴリズムを適用し、季節調整値の推定を行う。

なお、上記の Step 2-1 の計算において、 S^{-1} の初期値をゼロ行列（全ての成分がゼロ）と置いている。これにより、初期分布が $V_{0|0} = (S^{-T}S^{-1})^{-1} = \infty \cdot I_d$ となり（初期の情報がないという状況）、初期値の設定に伴う影響を抑えることが可能となる（ここで $c_0 = S^{-1}x_{0|0} = 0$ ）。

3 数値実験による評価

これまでに述べたモデルについて、人工的なデータを用いた数値実験により、提案手法の推定のパフォーマンスを評価する。ここでは「真の」季節性が既知の場合にどの程度の精度で季節調整値を推定することができるかを見る。

3.1 実験データの作成

提案手法の有効性について確認するために、人工的に作成した実験データを用いて、性能についての確認を行うこととする。実験用データは、以下の手順に従って作成している。ここで、「真の」チューニングパラメータ λ は、0.75 に設定している。

$$T_n = 0.95 * T_{n-1} + v_{1n} \quad v_{1n} \sim N(0, 10) : \text{トレンドの発生機構}$$

$$S_n = -S_{n-1} - S_{n-2} - S_{n-3} + v_{2n} \quad v_{2n} \sim N(0, 1)$$

$$S_1 = 50, S_2 = -50, S_3 = 100 : \text{季節性の発生機構}$$

$$I_n \sim N(0, 12) : \text{不規則変動の発生機構}$$

$$X_n = T_n + S_n + I_n : \text{原系列の neg-log 変換後の値}$$

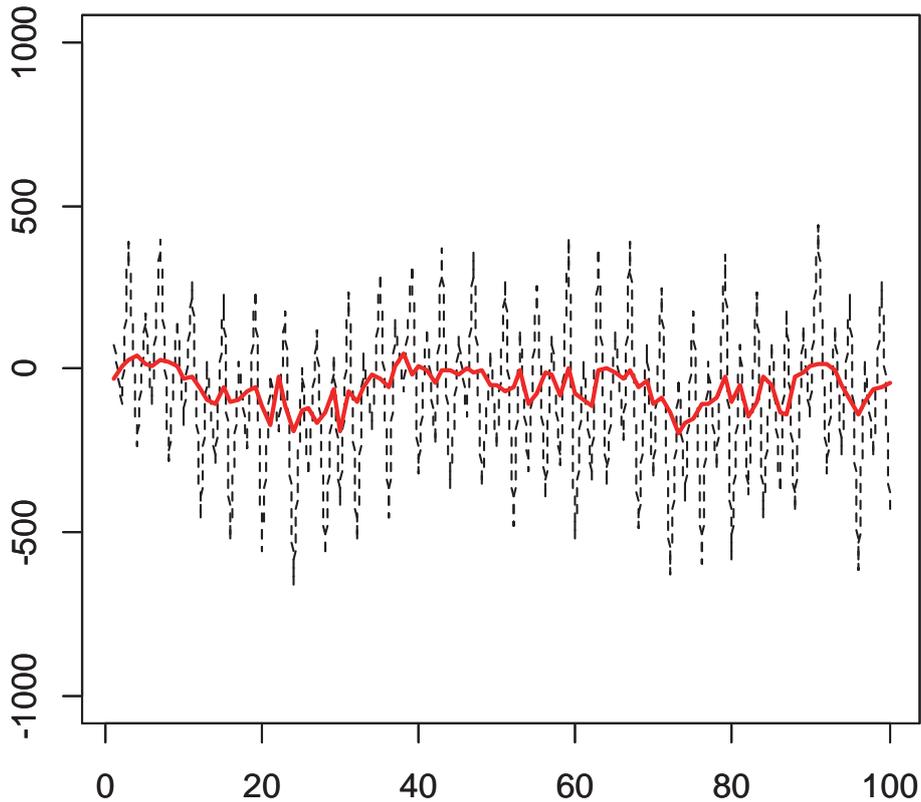
$$Y_n = X_n - S_n : \text{季節調整済みの neg-log 変換後の値}$$

$$A_n = f_{neg-log}^{-1}(X_n) : \text{原系列の実験用データ}$$

$$B_n = f_{neg-log}^{-1}(Y_n) : \text{季節調整済み系列の実験用データ（「真の」季節調整済み系列）}$$

以上のようにして作成した、数値実験用データについて、原系列 (A_n : 点線) と「真」のトレンド (B_n : 実線) とを重ねて描いたものが、以下の図2である。実験用データであれば、「真」の値があらかじめわかっているので、各種の季節調整法の精度を比較することができる。

図2 人工データと「真」の季節性



3.2 λ の推定結果及び推定した λ に基づく季節調整の結果

ここでは、3.1 節で示した数値実験用データについて、一般化 neg-log 変換により、データから推定される季節調整済み系列がどの程度安定するのか、またどの程度真の季節性をとらえているのか、という点について確認する。ここで、 λ を様々な値に動かすことを考える。各 λ に対応する変換後の時系列に対して、提案手法により推定を行った場合の AIC の値を示したグラフが、図3である。ただし、一般化 neg-log 変換によって、対象となる時系列データそのものが変化してしまうことから、単純に AIC を計算すると、それらを比較することができなくなる。そこで、実際の計算では、一般化 neg-log 変換の微分を用いて、尤度の調整を行っている（北川（2005））。図3によると、チューニングパラメータ λ を 0.74 とした場合に、AIC が最も小さい値となっており、これは事前に設定したチューニングパラメータ λ の値（=0.75）に非常に近くなっている。このようにして求めた λ に基づいて推定した季節調整値と、単純なモデルによる季節調整値との比較を行った結果を示したものが、図4である。単純なモデルに基づく季節調整値は、真の季節性とずれており、しかも真の値から下方にずれていて、何らかのバイアスがあるようにみえる。これに対して、提案手法による推定値は、真の季節調整値とほとんど重なっているようにみえる。よって、数値実験の結果からは、提案手法による季節調整値の推定は、ある程度適切な値になっているといえる。

以上をまとめると、提案手法によって、未知のチューニングパラメータ λ を推定しつつ、それを用いた一般化 neg-log 変換によって時系列の変動を抑えることで、季節調整値の推定精度を、ある程度向上させることができるということが示されたといえる。

図3 λとAICとの関係

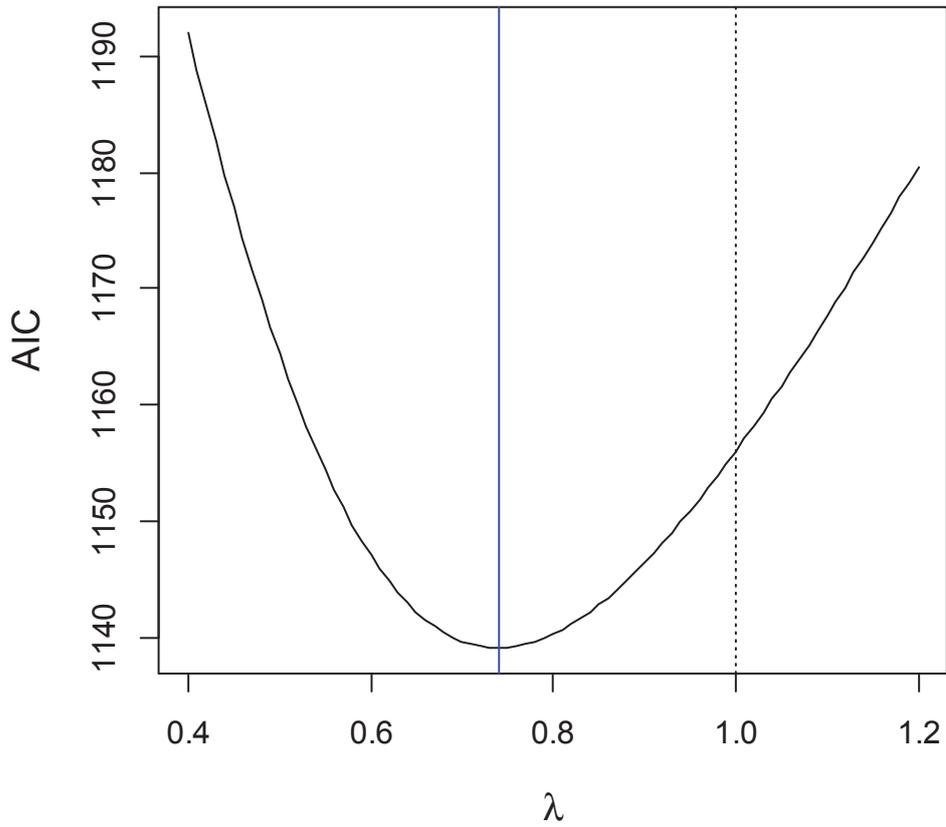
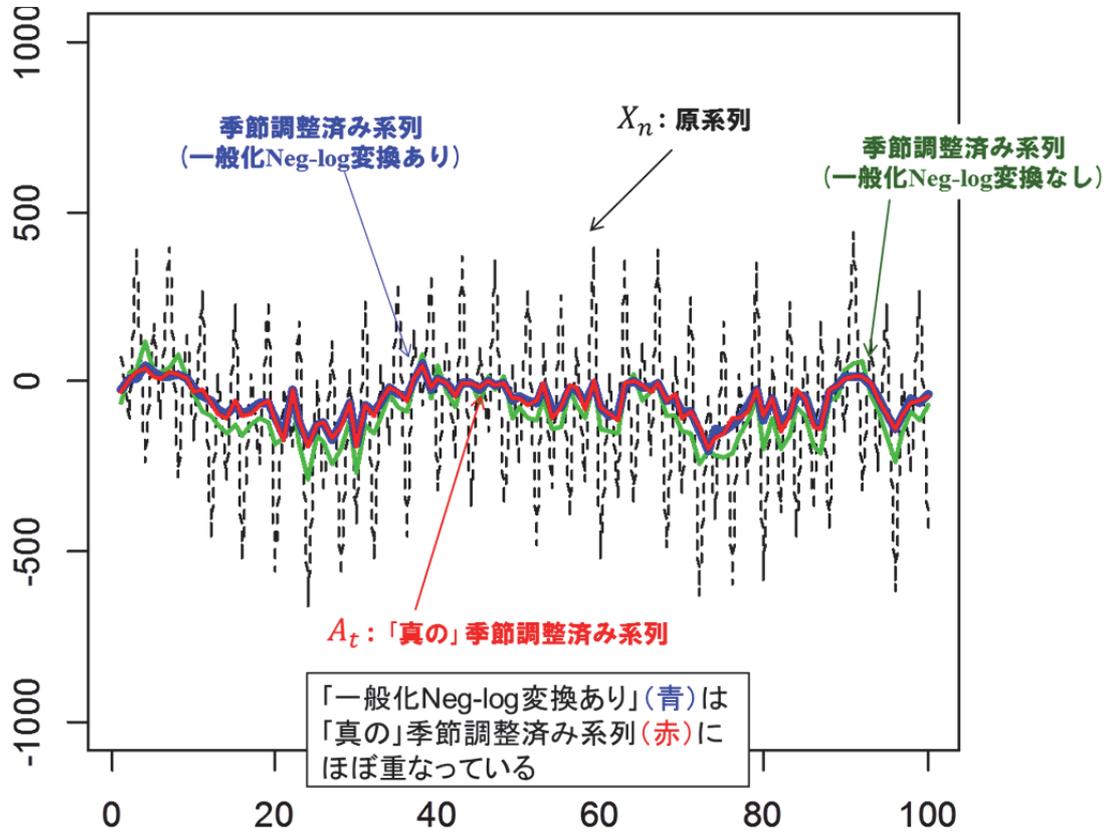


図4 各手法に基づく季節調整値の比較



4 実データに基づく推定

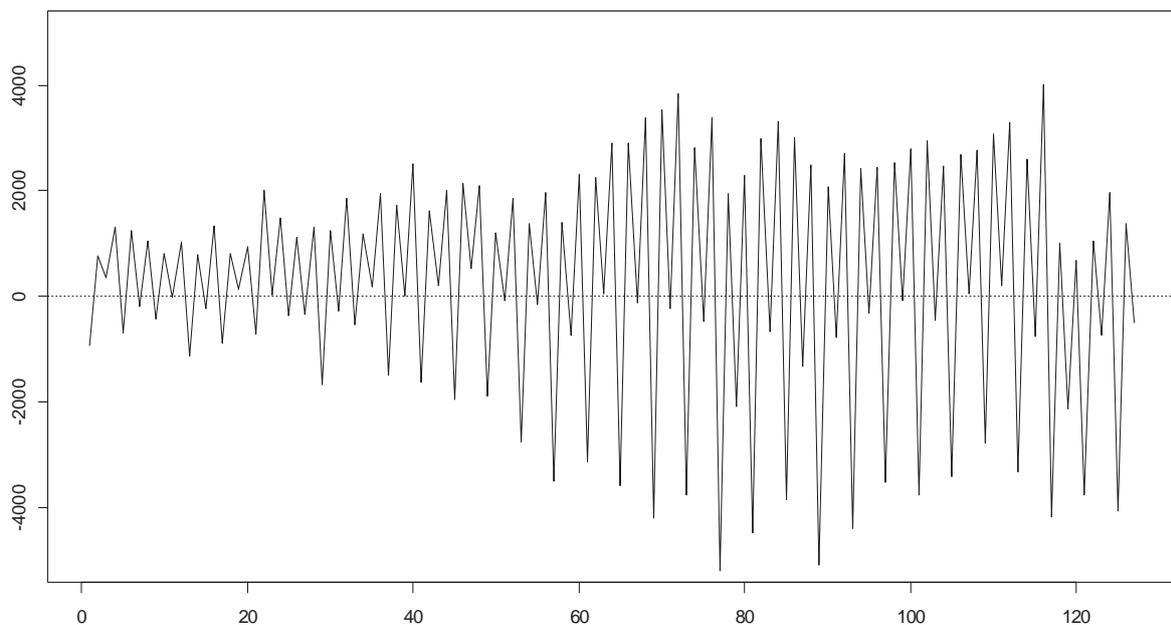
ゼロや負の値を含む2つの実データに対して、提案手法を適用し、その結果を分析する。

4.1 国内総生産・民間在庫品増加

奥本（2000）では、ゼロや負の値を含んでいて単純に変数変換等を行うことができない時系列として、国内総生産における民間在庫品増加が挙げている。以下では、この時系列について、提案手法を適用した結果について説明する。

以下の図は、内総生産における民間在庫品増加の時系列を示したものである。グラフを見ると、ゼロを中心として、大きく変動していることがわかる。また、時点によって振れ幅が異なるので、不規則変動が分散一定の正規分布に従うという仮定も、疑わしいものとなっている。このような場合に提案手法を用いることで、時系列の変動を安定化させて、季節調整値の精度を高めることができるものと期待される。

図5 国内総生産・民間在庫品増加（実質原系列）
期 間：1980年1-3月期～2011年7-9月



上記の時系列に対して、提案手法によって、 λ を推定した結果を示したものが、以下の図6である。図6では、 λ をグリッドに刻んで、グリッドの値ごとに計算されたAICを折れ線をつなぐことによってグラフを描いている。この図を見ると、 λ が0.8の付近でAICのカーブは極小値をとっていることがわかる。数値的最適化によって λ の値を正確に求めると、0.814と推定される。

次に、推定された λ を用いて、提案手法により、季節調整を行う。計算結果については示したものが、以下の図7である。提案手法とともに、変換を行わずに季節調整を適用した結果も合わせて示している。提案手法を適用することで、時系列データの変動が抑えられ、最終的な季節調整値の変動も安定している。

図6 λとAICの関係 (国内総生産・民間在庫品増加)

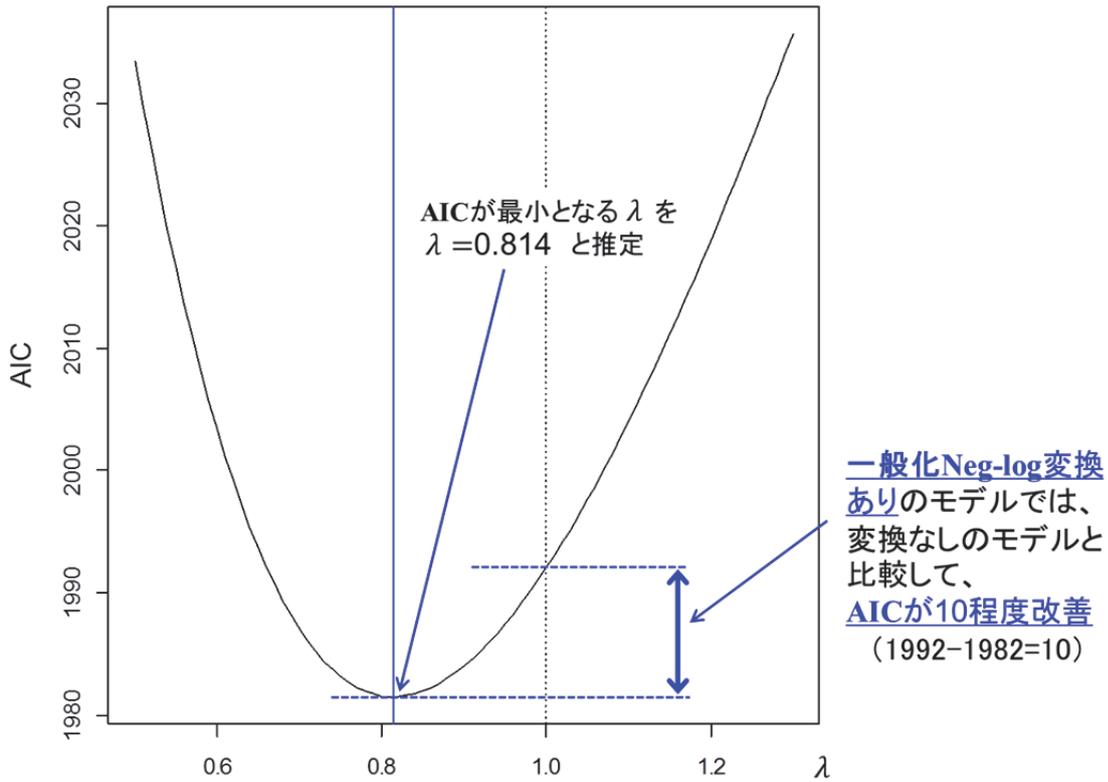
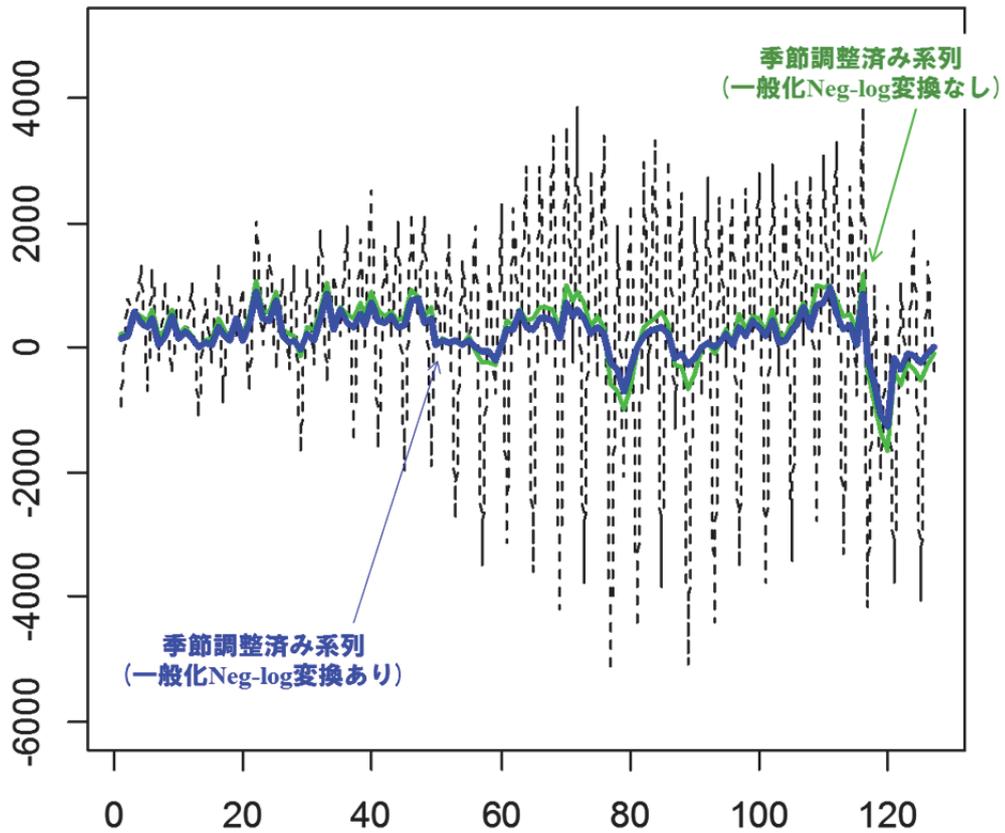


図7 単純な方法と提案手法による季節調整結果の比較 (国内総生産・民間在庫品増加)

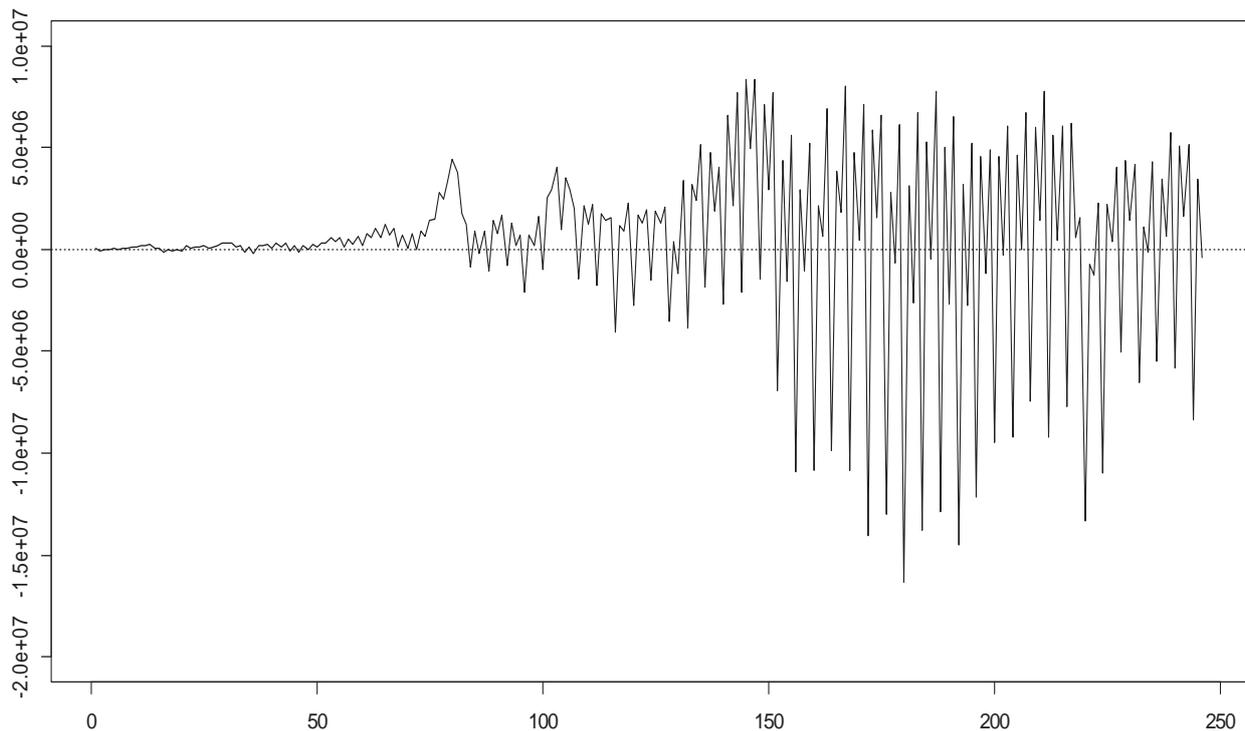


4.2 法人企業統計・在庫品増加

奥本（2000）では、単純に変数変換等を行うことができない時系列として、法人企業統計調査の在庫品増加についても例に挙げている。以下では、この時系列について、提案手法を適用した結果について説明する。

法人企業統計・在庫品増加の時系列の推移を示したものが、図8である。このグラフを見ると、ある程度の季節性があるようにみえるが、時期によって振幅はかなり異なっており、そのまま季節調整法を適用すると、結果に相当な歪みが出る可能性がある。

図8 法人企業統計 時系列データ(全産業(除く金融保険業), 全規模)在庫品増加
期 間：1954年4-6月期～2015年7-9月



上記の時系列に対して、提案手法によって、 λ を推定した結果を図6と同様の方法により示したものが、以下の図9である。図9を見ると、 λ が0.7の付近でAICは最小となり、数値的最適化によって λ の値を正確に求めると、0.714と推定される。

次に、推定された λ を用いて、提案手法により季節調整を行う。計算結果について示したものが、以下の図10である。図7と同様に、提案手法とともに、変換を行わずに季節調整を適用した結果も示している。本稿で提案した手法を適用することで、国内総生産の時系列データと同様に、法人企業統計データにおいても変動が抑えられ、最終的な季節調整値の変動は安定している。特に、時系列の後半において、通常の方法では、時系列の変動に影響されて、季節調整結果が下方に引きずられているのに対して、提案手法による季節調整値は、変動が抑えられていることが確認できる。

図9 λとAICの関係 (法人企業統計・在庫品増加)

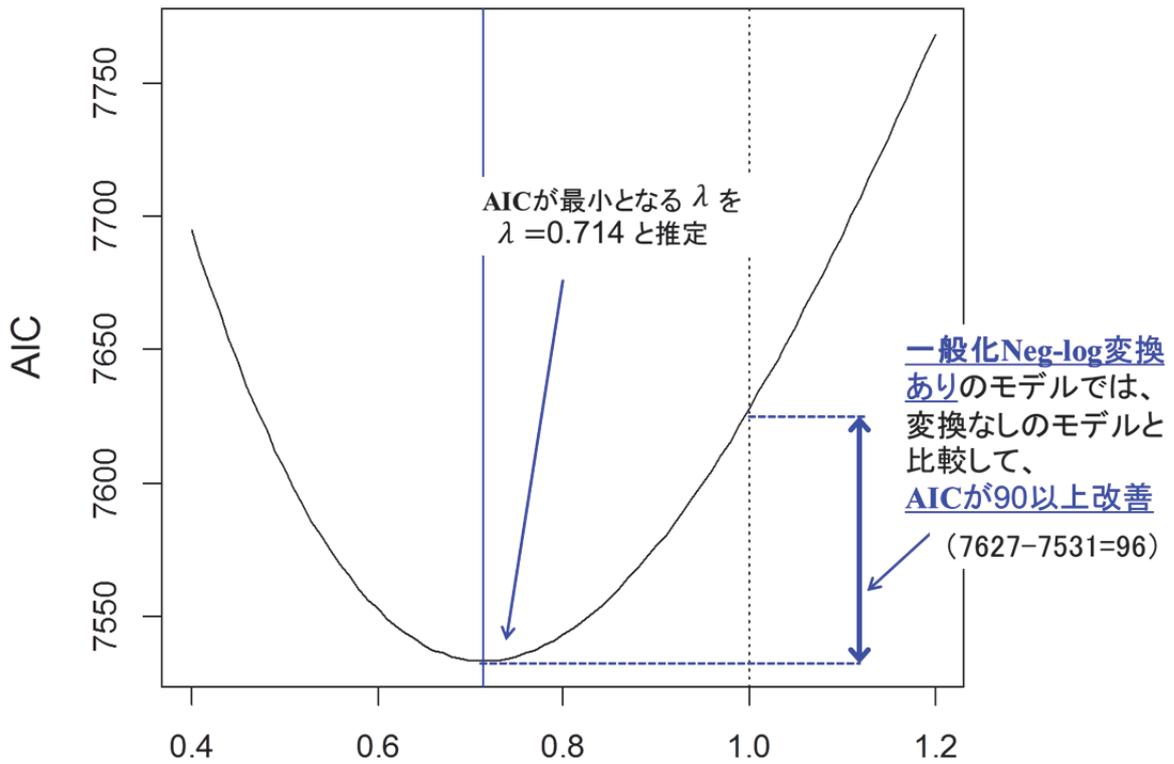
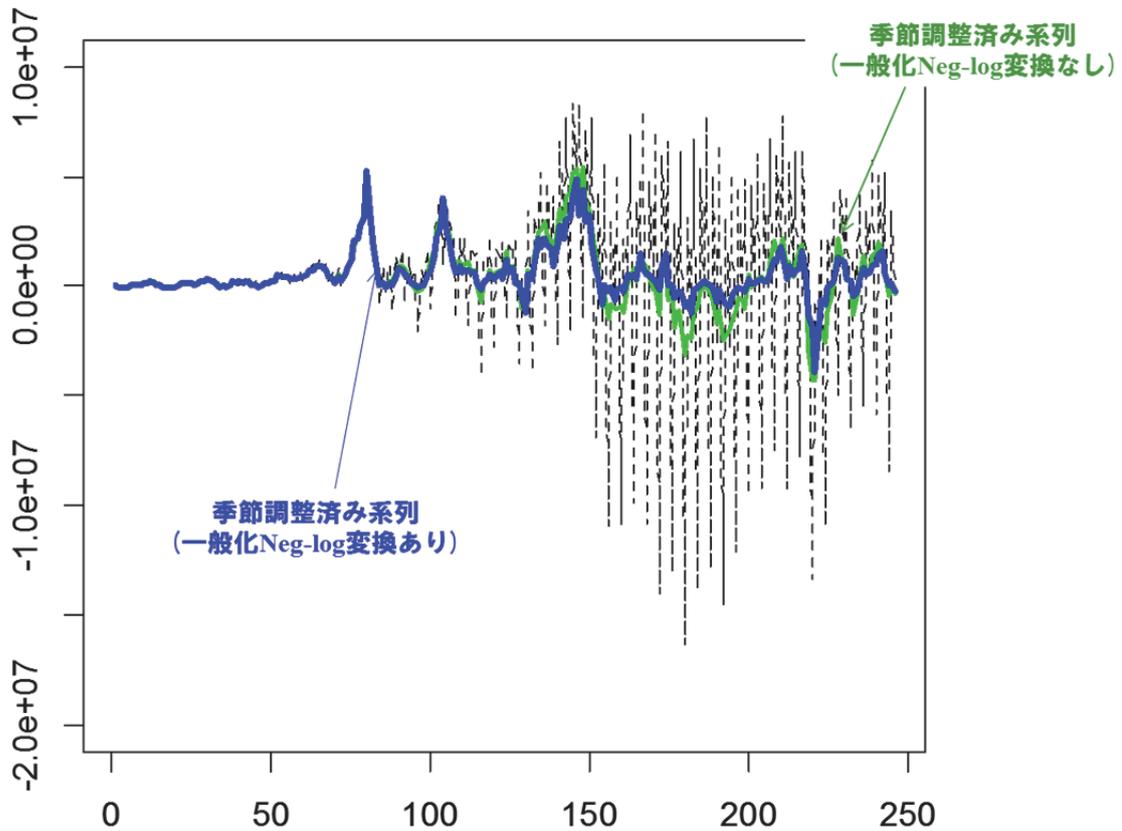


図10 単純な方法と提案手法による季節調整結果の比較 (法人企業統計調査・在庫品増加)

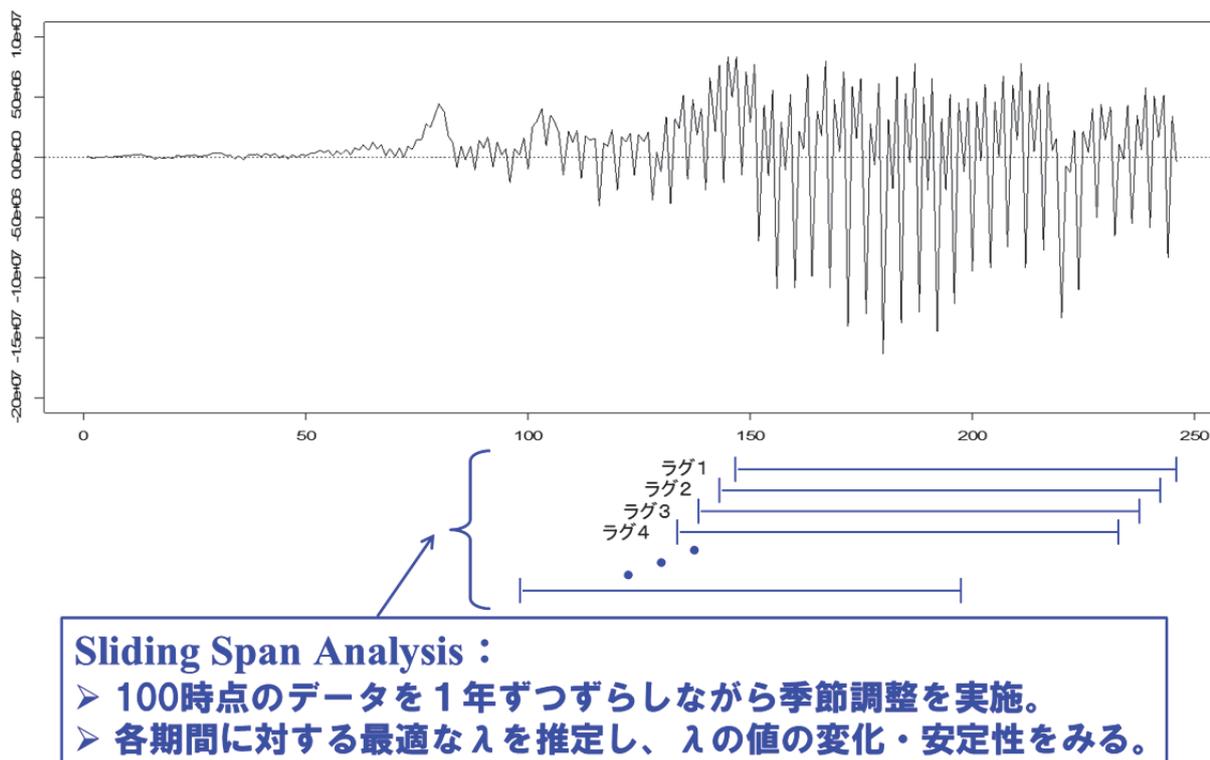


4.3 法人企業統計・在庫品増加：スライディング・スパン分析によるパラメータの安定化に関する分析

この節では、推定された λ パラメータの安定化について検討する。データの圧縮率である λ が不安定である場合には、季節調整値を推定するための期間を注意深く選択する必要がある。推定結果の安定性の確認には、Sliding Span Analysis の手法を用いる。これは、X-12 ARIMA に搭載されている結果精度の確認手法である。Sliding Span Analysis では、推定期間が異なる場合の、モデルや季節調整値の変動に注目する。具体的には、推定する期間を少しずつずらした、複数の期間のデータを考えて、それらの各データに対してそれぞれ季節調整法を適用し、得られた複数の季節調整の結果を比較することで、データが新たに加わった場合の推定結果の変動を見ることができる。期間をずらしながら分析を行うことから、Sliding Span Analysis と呼ばれている。

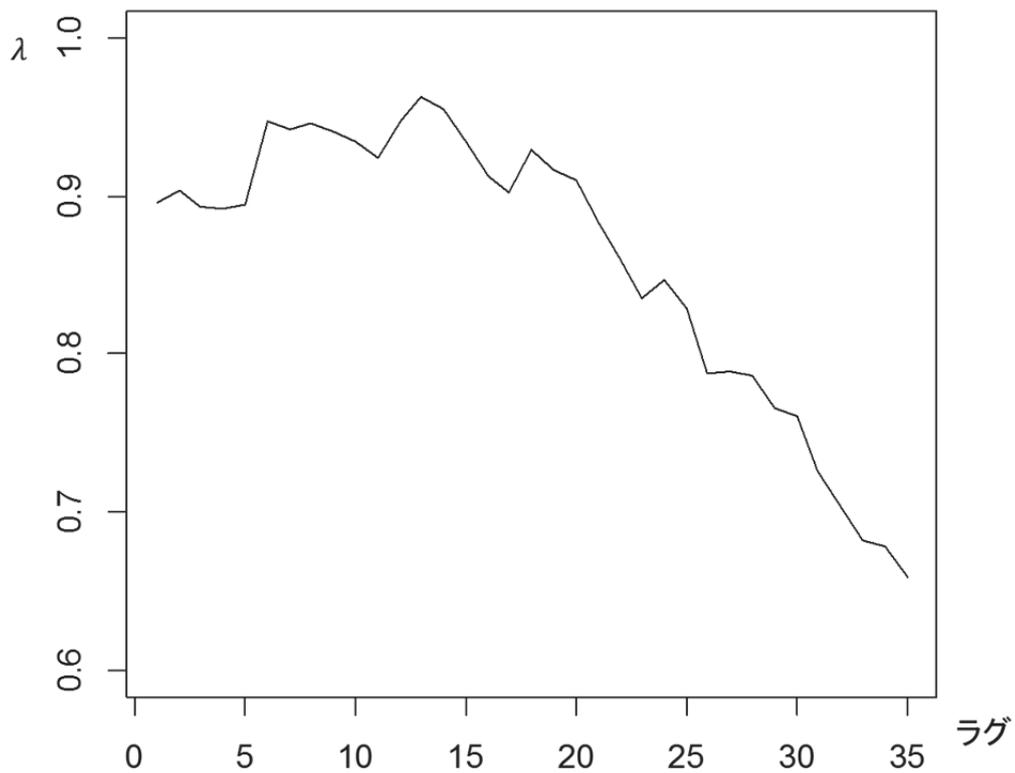
この Sliding Span Analysis の考え方を応用して、法人企業統計・在庫品増加の時系列データに提案手法を適用した際の、チューニングパラメータ λ の安定性を見る。Sliding Span Analysis を適用する期間の幅は 100 時点に設定した。この 100 時点分のデータを 1 時点ずつ、ずらしながら、提案手法による季節調整を適用し、各期間における最適な λ を推定し、 λ の値の変化・安定性を見た。以上の計算の考え方を示したものが、以下の図 11 である。

図 11 Sliding Span Analysis の考え方



上記の Sliding Span Analysis の分析結果に基づく、期間ごとのチューニングパラメータ λ の推移を示したものが、以下の図 12 である。ここで「ラグ」とは、期間を何期分ずらしたのかを表している。

図12 Sliding Span Analysis の結果



Sliding Span Analysis の結果を見ると、推定を行う期間に対して、チューニングパラメータ λ の値は安定しておらず、ある程度の変動があることが確認された。このことから、変動の大きさが急激に変化するような時系列に対しては、適用する期間をある程度制限した上で季節調整を適用することが望ましいと考えられる。

また、期間の変更に伴う λ の変動を見ていくことで、時系列が安定する期間はいくらなのかを把握することに利用できる可能性がある。

おわりに

本稿では、季節調整の精度を向上させるために、一般化 neg-log 変換を用いて事前に時系列の変動を安定化させた上で、カルマンフィルタよりも精度の高い Information Square Root Filter に基づく季節調整法を適用することで、季節調整値の推定結果の精度向上を図っている。提案手法による数値実験は良好な結果を示している。推定の結果、単純な状態空間モデルに基づく手法と比較して、季節調整値の推定精度が向上し、実データに基づく推定では、推定結果の変動が抑えられ、季節調整値が安定することが確認された。また、Sliding Span Analysis では、ラグに応じて λ の値が変動することが確認できた。この事実を利用することで、時系列が安定する期間の把握や既存の季節調整法のチェックに活用できる可能性がある。なお、本結果は状態空間モデルに基づく手法の枠組内での改善について示したものであり、他の季節調整法 (X-12-ARIMA 等) による結果の比較は行っていない。他の時系列データへの適用と推定結果の比較についても行う必要があるが、これらの分析は、今後の課題としたい。

時系列データの分布の安定化という意味では、一般化 neg-log 変換のほかにも、多種多様な変換方法がある。今後の課題としては、さらなる安定化のための変換を適用することが考えられる。本稿でも示した Yeo-Johnson 変換は、その一つの候補である。なお、これらの変換では、1つのチューニングパラメータ λ で変換の強さをコントロールすることになるが、例えば2つのチューニングパラメータを用いて、分布の中心から見て、左右で別々のチューニングパラメータにより、変換を行う手法も考えられる。また、本稿では、予測の観点から最も優れているモデルを推測するという、AIC を用いた「最適性」の観点から、モデル選択の考え方に基づいて λ を探索している。一方、実務の観点からは、季節調整値の「安定性」も、重要な課題であり、例えば何らかの安定化の指標（1年間の遡及改定の変動など）から見て、最良の λ を決定する方法も考えられる。さらに金融時系列の分野では、非対称かつ極度に歪んだ分布を想定した skewed Kalman filter が活用されている (Naveau et al. (2005))。また、ゼロで切断された分布について、ゼロ以下の値をとる観測できない潜在変数を導入して、MCMC 法により推定を行う手法も開発されている (青木ほか (2012))。これらの手法を取り入れることによって、より精密な季節調整値の推定を行うことができると期待される。それらの推定結果は、実務で用いられている推定手法のチェック機能を果たすという意味では、十分に実用可能な手法になると考えられる。

なお、高部 (2009) において、今後の課題として、時系列からの安定的な季節変動の抽出について言及しており、そのための方法の一例として、ウェーブレット解析の適用について触れている。本稿では、状態空間モデルに基づく季節調整法の改良について扱っているが、変動の激しい時系列データの安定化と、その観点を踏まえた適切な季節変動の除去という意味では、追及しているテーマ・方向性は、上記の課題と同一であり、むしろ本稿で提案した手法の方が、ウェーブレット解析よりも柔軟で計算しやすい方法により、推定精度の向上を図っているといえる。よって、本稿の成果をもって、高部 (2009) の課題への、一つの対応方策を示すことができたと考えている。

付録：本稿における計算に用いたプログラム

```

ISRF.core <- function(par, data, S0, rev, opt) {
  tau2 <- trans(par)
  U <- diag(1/sqrt(tau2))
  S <- S0
  sig2 <- ld <- JB <- 0
  for (t in 1:N) {
    R <- R00
    R[1:L, 1:L] <- U
    R[L1:LM, L1:LM] <- SFI <- S[1:M, 1:M] %*% FI
    R[L1:LM, 1:L] <- -SFI %*% G
    R[L1:LM, LM1] <- S[1:M, M1]
    R <- qr.R(qr(R))
    S <- S00
    S[1:M, 1:M] <- RI <- R[L1:LM, L1:LM]
    S[1:M, M1] <- b <- R[L1:LM, LM1]
    S[M1, 1:M] <- H
    S[M1, M1] <- Zt <- g.nl.trans(data[t])
    S <- qr.R(qr(S))
    if (rev == 0) {
      XP <- backsolve(RI, b)
      d <- tcrossprod(H %*% t(RI)) + 1
      sig2 <- sig2 + (Zt - H %*% XP)^2 / d
      ld <- ld + log(d)
    }
    if (opt == 0) RPS[, , t] <- R[1:L, 1:LM1]
    if ((opt+rev) == 0) JB <- JB + log(g.nl.d(data[t]))
  }
  if (rev == 1) return(S)
  if (rev == 0) {
    sig2 <- sig2/N
    LKHD <- -0.5*(N*(log(2*pi*sig2) + 1) + ld)
    if (opt == 1) return(-LKHD)
  }
  AIC <- -2*(LKHD + JB) + 2*(L+1+M)
  XSS[, N] <- XS <- backsolve(S[1:M, 1:M], S[1:M, M1])
  for (t in (N - 1):1) {
    W <- RPS[, 1:L, t+1]
    T <- RPS[, L1:LM, t+1]
    A <- RPS[, LM1, t+1]
    VN <- backsolve(W, A - T %*% XS)
    XSS[, t] <- XS <- FI %*% (XS - G %*% VN)
  }
}

```

高部 勲：状態空間モデルに基づく季節調整法における改良方法の提案：一般化 `neg-log` 変換の活用に基づく
ゼロ・負の値を含む時系列データの安定化と季節調整値の推定精度向上

```
list(LKHD = LKHD,
     AIC = AIC,
     par = c(tau2[1], tau2[2], sig2),
     XSS = XSS)
}

ISRF <- function(param, opt) {
  S0 <- ISRF.core(param, dt[order(N:1)], S00, 1, 0)
  X0 <- backsolve(S0[1:M, 1:M], S0[1:M, M1])
  Y0 <- state.pred(X0)
  S0[1:M, M1] <- S0[1:M, 1:M] %*% Y0
  ISRF.core(param, dt, S0, 0, opt)
}

LKHD.fun <- function(param) ISRF(param, 1)

get.AIC <- function(lam) {
  lambda <- lam
  op <- optim(i.trans(init.par), LKHD.fun, method="BFGS")
  ISRF.res <- ISRF(op$par, 0)
  cat("lambda:", lambda, " ")
  cat("AIC :", ISRF.res$AIC, "¥n")
  ISRF.res$AIC
}

state.pred <- function(Z0) {
  Z1 <- F %*% Z0
  Z2 <- F %*% Z1
  Z3 <- F %*% Z2
  c(Z1[1:2,], Z2[2,], Z3[2,])
}

state.dcmp <- function(ZSS) {
  trend <- seasonal <- irregular <- s.adjust <- rep(NA, N)
  for (t in 1:N) {
    trend[t] <- ZSS[1, t]
    seasonal[t] <- ZSS[2, t]
    s.adjust[t] <- g.nl.trans(dt[t]) - seasonal[t]
    irregular[t] <- s.adjust[t] - trend[t]
  }
  list(trend = i.g.nl.trans(trend),
       seasonal = i.g.nl.trans(seasonal),
       s.adjust = i.g.nl.trans(s.adjust),
       irregular = i.g.nl.trans(irregular))
}
```

```

}

trans <- function(par) 0.5*(1 + sin(par)) + 0.0001
i.trans <- function(par) asin(2*par - 1)

g.nl.trans <- function(Z) {
  if (lambda == 0) return(sign(Z)*log(abs(Z)+1))
  if (lambda == 1) return(Z)
  sign(Z)*((abs(Z)+1)^lambda-1)/lambda
}

i.g.nl.trans <- function(Z) {
  if (lambda == 0) return(sign(Z)*(exp(abs(Z))-1))
  if (lambda == 1) return(Z)
  sign(Z)*((abs(Z*lambda)+1)^(1/lambda)-1)
}

g.nl.d <- function(Z) {
  if (lambda == 0) return(1/(abs(Z)+1))
  if (lambda == 1) return(1)
  (abs(Z)+1)^(lambda-1)
}

graph <- function(data, p, yl, lt, wd, cl) {
  if(p == 1) par(new = T)
  plot(data,type="l",ylim=yl,lty=lt,lwd=wd,col=cl,xlab="",ylab="")
}

print.par <- function(ISRF.result) {
  cat("lambda:", lambda, "\n")
  cat("tau2.t:", ISRF.result$par[1], " ")
  cat("tau2.s:", ISRF.result$par[2], " ")
  cat("sig2:", ISRF.result$par[3], " ", "\n")
  cat("AIC :", ISRF.result$AIC, "\n")
  cat("LKHD:", ISRF.result$LKHD, "\n")
}

lambda.opt <- function(intvl) {
  opt.lam <- optimize(get.AIC, intvl)
  opt.lam$minimum
}

main.program <- function() {
  op <- optim(i.trans(init.par), LKHD.fun, method="BFGS")

```

高部 勲：状態空間モデルに基づく季節調整法における改良方法の提案：一般化 `neg-log` 変換の活用に基づく
ゼロ・負の値を含む時系列データの安定化と季節調整値の推定精度向上

```
ISRF.res <- ISRF(op$par, 0)
dcmp.res <- state.dcmp(ISRF.res$XSS)
print.par(ISRF.res)
list(par      = ISRF.res$par,
     AIC      = ISRF.res$AIC,
     trend    = dcmp.res$trend,
     seasonal = dcmp.res$seasonal,
     s.adjust = dcmp.res$s.adjust,
     irregular = dcmp.res$irregular)
}

test.data <- function() {
  T0 <- rep(0, 100)
  for (t in 2:100) {
    T0[t] <- 0.95*T0[t-1] + rnorm(1, 0, 10)
  }
  T0 <- T0
  S0 <- rep(0, 100)
  S0[1] <- 50
  S0[2] <- -50
  S0[3] <- 100
  for (t in 4:100) {
    S0[t] <- -S0[t-1] - S0[t-2] - S0[t-3] + rnorm(1, 0, 1)
  }
  S0 <- S0
  I0 <- rnorm(100, 0, 12)
  TSI0 <- T0 + S0 + I0
  TSI <- i.g.nl.trans(TSI0)
  TS0 <- T0 + I0
  TS <- i.g.nl.trans(TS0)
  list(TSI = TSI, TS = TS)
}

#dt <- scan("D:/ZAIKO.data.txt")
dt <- scan("D:/GDP.data.txt")

N <- length(dt)
L <- 2
M <- 4
M1 <- M + 1
L1 <- L + 1
LM <- L + M
LM1 <- L + M + 1
```

```

R00 <- matrix(0, LM, LM1)
S00 <- matrix(0, M1, M1)
XSS <- matrix(NA, M, N)
RPS <- array(NA, c(L, LM1, N))

F <- matrix(0, M, M)
F[1, 1] <- F[3, 2] <- F[4, 3] <- 1
F[2, 2:4] <- -1
FI <- solve(F)
G <- diag(1, M, L)
H <- matrix(c(1, 1, 0, 0), 1, M)

init.par <- c(0.6, 0.1)
yl <- c(0, 120000)

lambda <- 1
result1 <- main.program()
graph(dt, 0, yl, 2, 1, "black")
graph(result1$s.adjust, 1, yl, 1, 2, "green3")

lambda <- lambda.opt(c(0, 1))
result2 <- main.program()
graph(dt, 0, yl, 2, 1, "black")
graph(result1$s.adjust, 1, yl, 1, 2, "green3")
graph(result2$s.adjust, 1, yl, 1, 2, "red")

```

[プログラムにおける各関数の役割]

ISRF.core : Information Square Root Filter アルゴリズムにより状態推定、尤度計算等を行う。
 ISRF : 時間を逆転させた時系列に基づいて計算した状態ベクトルの初期分布を用いて、
 Information Square Root Filter アルゴリズムにより、状態推定を行う。
 LKHD.fun : 1期先予測誤差を基に、対数尤度の計算を行う。
 get.AIC : 与えられたチューニングパラメータ λ に対する AIC の値を計算する。
 state.pred : 1期先から3期先までの予測値に基づき、初期分布(平均値)を求める。
 state.dcmp : 状態ベクトルの推定値を基に、トレンド、季節性、季節調整値等を計算する。
 trans : ハイパーパラメータが、 $0 \sim 1$ の範囲に収まるように変換する。
 i.trans : ハイパーパラメータが、 $-\infty \sim +\infty$ の値を取ることができるように変換する。
 g.nl.trans : 一般化 neg-log 変換の計算。
 i.g.nl.trans : 一般化 neg-log 変換の逆変換の計算。
 g.nl.d : 一般化 neg-log 変換の微分の計算。
 graph : 色・線の種類等を設定して、グラフを描画する。
 print.par : 推定した各種パラメータを画面に表示する。
 lambda.opt : get.AIC で得られる λ と AIC の関係から、AIC が最小となる λ を探索する。
 main.program : メインプログラム。提案手法に基づく季節調整値の推定を行う。
 test.data : 本稿で示した方法により、数値実験用のテストデータを作成する。

参考文献

- [1] 青木義充, 横内大介, 加藤剛(2012), 「値幅制限を考慮した商品先物価格の実証分析: MCMC による先物商品価格のモデル化を利用して」, 『市場構造分析と新たな資産運用手法 (ジャーナル・ジャーナル: 金融工学と市場計量分析)』, 朝倉書店, 16-55.
- [2] 有田帝馬(2012), 「入門季節調整: 基礎知識の理解から X-12-ARIMA の活用法まで」, 東洋経済新報社.
- [3] 奥本佳伸(2000), 「季節調整法の比較研究 —センサス局法 X-12-ARIMA の我が国経済統計への適用—」, 政策研究の視点シリーズ第 17 号, 内閣府経済社会総合研究所.
- [4] 片山徹(2000), 「新版 応用カルマンフィルタ」, 朝倉書店.
- [5] 片山徹(2011), 「非線形カルマンフィルタ」, 朝倉書店.
- [6] 北川源四郎(1997)季節調整プログラム DECOMP とその後の展開, 統計数理, 45(2), pp.217-232
- [7] 北川源四郎(2005), 「時系列解析入門」, 岩波書店.
- [8] 国友直人編(2001), 「季節調整法 X-12-ARIMA(2000)の利用: 法人企業統計の事例」, CIRJE-J-58, 東京大学日本経済国際共同研究センター.
- [9] 国友直人編(2004), 「解説 X-12-ARIMA(2002)」, CIRJE-R-1, 東京大学日本経済国際共同研究センター.
- [10] 今野浩, 山下浩(1978), 「非線形計画法」, 日本科学技術連盟.
- [11] 福島雅夫(2011), 「新版 数理計画入門」, 朝倉書店.
- [12] 佐藤整尚(1997)「Web Decom の紹介-WWW 上で行う季節調整システム」, 『統計数理』, 45, 2, 統計数理研究所, 145-161.
- [13] 高橋淳一(2015) 財務諸表データに対する欠損値補完及び外れ値処理について、総合研究大学院大学博士論文.
- [14] 田上悠太, 山下智志(2015), 「デフォルト企業の正常復帰に関する要因分析と正常復帰確率推定モデル」, 『統計数理』, 63, 1, 統計数理研究所, 145-161.
- [15] 高岡慎(2016), 「経済時系列と季節調整法」, 朝倉書店.
- [16] 高部勲(2009), 「季節調整法 TRAMO-SEATS 法の分析」, 『統計研究彙報』, 66, 総務省統計研修所, 33-75.
- [17] 野木森稔(2013), 「季節調整法に関する最近の動向: X-12-ARIMA から X-13ARIMA-SEATS へ」, 『季刊国民経済計算』, 150, 41-58.
- [18] 松本正博, 松本雅子, 森本聡(2010), 「家計調査季節調整法の変更について」, 『統計研究彙報』, 67, 総務省統計研修所, 23-53.
- [19] 森正武(1987), 「FORTRAN77 数値計算プログラミング (岩波コンピュータサイエンス)」, 岩波書店.
- [20] 森平爽一郎(2009), 「信用リスクモデリング—測定と管理」, 朝倉書店.
- [21] 山下智志, 三浦翔(2011), 「信用リスクモデルの予測精度」, 朝倉書店.
- [22] Genshiro Kitagawa and Will Gersch(1994), “A Smoothness Priors State Space Approach to the Modeling of Time Series With Trend and Seasonality”, The Journal of the American Statistical Association, 79, 378-389.
- [23] Genshiro Kitagawa and Will Gersch(1996), “Smoothness Priors Analysis of Time Series”, Springer Verlag.
- [24] J. A. John and N. R. Draper(1980), “An Alternative Family of Transformations”, Journal of the Royal Statistical Society. Series C, 29, 2, 190-197.
- [25] P. G. Kaminski, A. E. Bryson and S. F. Schmidt(1971), “Discrete Square Root Filtering a Survey of

- Current Techniques”, IEEE Trans. Automatic Control, AC-16, 727-736.
- [26] Naveau, P., Genton, M. G. and Shen, X.(2005), “A skewed Kalman filter”. Journal of multivariate Analysis, 94, 2, 382-400.
- [27] UNECE(2012), “Practical Guide to Seasonal Adjustment With Demetra+”.
- [28] Yeo, I. and Johnson, R.(1998), “A new family of power transformations to improve normality or symmetry”, Technical Report No.1002, Department of Statistics, University of Wisconsin
- [29] 統計数理研究所(2016), “TIMSAC for R package”, <http://jasp.ism.ac.jp/ism/timsac/>

高部 勲：状態空間モデルに基づく季節調整法における改良方法の提案：一般化 neg-log 変換の活用に基づく
ゼロ・負の値を含む時系列データの安定化と季節調整値の推定精度向上