

英国統計学会の統計検定試験 —季節調整関連問題の解答例—

本解答例は、英国統計学会（The Royal Statistical Society、以下 RSS¹⁾）が公表している Higher Certificate 試験に関する解答例のうち、見本問題および 2007 年から 2010 年までの季節調整に関連する問題の解答例を、RSS より許諾を受け暫定的に訳したものである。

なお、本解答例は学習の利便のため、実際に必要と思われる解答より詳細な記述となっている。このため、モデル的な模範解答とは異なる点には注意されたい。

<見本問題> Module7: Time series and index numbers

Question 1

(i)

(A) 加法型分解モデルは、 $O_t = T_t + S_t + I_t$ と表現される（ここではトレンドを T_t と表記する）。よって、季節調整値 SA_t とトレンドの差は以下のように表現される。

$$SA_t - T_t = \{O_t - S_t\} - T_t = I_t$$

(B) 乗法型分解モデルは、 $O_t = T_t \times S_t \times I_t$ と表現される。よって、季節調整値 SA_t とトレンドの差は以下のように表現される。

$$SA_t - T_t = \{O_t / S_t\} - T_t = (T_t \times I_t) - T_t = T_t (I_t - 1)$$

(C) 疑似加法型分解モデルは、 $O_t = T_t + T_t (S_t - 1) + T_t (I_t - 1)$ と表現される。よって、季節調整値 SA_t とトレンドの差は以下のように表現される。

$$SA_t - T_t = \{O_t - T_t (S_t - 1)\} - T_t = T_t (I_t - 1)$$

(ii)

季節調整値とトレンドとの差は以下のように解釈できる。

加法型分解モデルの場合、季節調整値とトレンドとの差は不規則成分そのものになる。

一方、乗法型分解モデルおよび疑似加法型分解モデルの場合、季節調整値とトレンドとの差は不規則成分にはならないが、トレンドが安定的な場合は不規則変動に近いものになる。ただし、トレンドが大きくなるにつれ、 $T_t \times I_t$ と I_t の間の差異は大きくなる点は注意する必要がある。

(iii)

適切な分解モデルを見つけるには、加法型および乗法型の枠組みの元で、それぞれに対応する ARIMA モデルを時系列データに対して当てはめてみればよい。当てはまりの良さ

¹⁾ www.rss.org.uk

を判定する際には、標準的な情報量基準（たとえば、赤池情報量基準やバイズ情報量基準）を用いればよい。その値が小さいほうが適切なモデルということになる。

他の方法としては、季節変動成分が時系列的にみてどのように変化しているかを視覚的に確認することで、適切な分解モデルを決定することが可能である。季節変動成分と不規則変動成分の積が急激に変化しており、季節変動成分が季節変動をうまくとらえきれていない場合、選択した分解モデルが不適切であった可能性がある。季節変動の振れの大きさと時系列データの水準との間に比例的な関係がみられるのであれば、乗法型モデルを選択することが考えられるだろう。

Question 2

- (i) 不規則変動
- (ii) 季節成分
- (iii) トレンド
- (iv) 季節成分
- (v)

(i) は、一時的な事象であることから、一時的な事前調整を適用する。

(ii) は 2 つの解答が可能である。一つは、季節調整の手順は十分に頑健であることから、その変化の大きさにもよるが、季節要素が緩やかに経時的に変化する場合であれば、季節要素自体の変化として対応することが可能と考えられる。もう一つの解答としては、一時的な事前調整により調整することも考えられる。

(iii) は、季節成分の推定値を改善するため、一時的な事前調整を適用する。

(iv) は、暦に関係する影響であり、最終的な季節調整値から取り除くべき変動であることから、恒久的な事前調整を適用する。

- (vi)

最も適切な方法は、(季節調整を行う前の) 原系列に対して **Reg-ARIMA** モデル、または **Reg-ARIMA** モデルの派生形を利用した手法を用いることである。この方法によれば、どのような事象の影響の大きさを推計する場合でも、季節調整を行う手順に伴う影響や歪みを受けることはない。たとえば、不規則変動成分を特定の事象の影響の推計のために利用しようとした場合、季節調整を行う手順が含まれるため、影響や歪みが潜在的に入り込んでしまう。

<2007 年> Module7: Time series and index numbers

Question 1

(i)

原系列は、加法型分解モデル、乗法型分解モデルを用いて、それぞれ以下のように表現できる。ただし、CT：トレンド（傾向循環変動）、S：季節変動、I：不規則変動、とする。

加法型分解モデル： $Y=CT+S+I$

乗法型分解モデル： $Y=CT\times S\times I$

季節調整値は、暦に関連した規則的な変動を推計し、これを原系列から除去したもの。季節調整値の中には不規則変動が残されているため、同一年の異なる時点間の比較を容易に行うことができる。季節調整を実行するためによく利用されているものとしては、フィルター型の季節調整法、たとえば X-12-ARIMA などがある。

一方、トレンドは、不規則変動の影響を緩和することを通じ、原系列が傾向的にどのように変化しているか明確になる。ただし、不規則変動の影響が緩和されることなどに伴い、ユーザーにとって有用な情報も同時に失われている可能性もある。この点、繰り返しフィルター型の季節調整法は、不規則変動の動きが残されるため、この問題は緩和されている。

(ii)

以下の事項が解答のポイントになる。

- ・季節調整は、年を跨いだ比較を可能とする。
- ・特殊な日、たとえば宗教的な祭り（復活祭、ラマダン、ディワリ等）、祝日等の休業日、複数の国を跨ぐ休日（春節等）の調整を、季節調整のモデルの中に組み込むことが可能である。
- ・季節調整は複雑な手順であるが、ユーザーによる説明のしやすさを向上させる。
- ・予測値を推計することで、データ端における季節要素の推計精度を向上できる可能性もある。
- ・フィルター型の季節調整では、新たなデータが加わった時に、データ端の季節調整値が大きく変わることがある。

(iii)

以下の事項が解答のポイントになる。

- ・ 対称型のフィルターと非対称型のフィルターの使い分け。
- ・ 季節調整やトレンド推計値は、異なるフィルターの利用や、季節調整の手順内にあるパラメータの変更を通じて、見直しが行われる。
- ・ 季節調整値を平滑化することで不規則変動の影響を減らすことができる。これにより、時系列データの傾向的な動きを把握しやすくなる。

(iv)

モデルを用いることで、時系列の推計を向上させる。その一つとして、時系列データの分解により、季節変動とトレンドの関係を明確にすることができることが挙げられる。

また、モデルによる原系列の予測値を利用することで、新たなデータが加わった時の季節調整やトレンド推計値の改定の影響を小さくすることを企図できる。たとえば、ARIMAモデルを用いて、データ端の部分について予測値を推計することがある。この予測値を利用することで、非対称フィルターを用いることの影響を小さくし、新たなデータが加わった時の季節調整やトレンド推計値の改定の影響を小さくすることができる。この際に重要なのは、適切な ARIMA モデルを選択することであり、不適切な ARIMA モデルを選択した場合には、季節調整値やトレンドの推計値の質を劣化させてしまう。

また、特定の事象の影響のモデル化、たとえば回帰分析により特殊な休日等やレベルシフト、外れ値、季節変動パターンの変化などの影響の推計を行うことも重要である。これにより、推計値の精度を向上させることができる。新たなデータが加わっていった場合に誤った推計値が改定されることから、このような影響はモデルに組み込んでおくべきだろう。

Question 2

(i)

原系列を O_t 、トレンドを T_t 、季節要素を S_t とする。このうち、 S_t に着目すると 1 に規格化されていることがわかる。よって、乗法型分解モデル ($O_t = T_t \times S_t \times I_t$) であることがわかる。

(ii)

乗法型分解モデルに沿った場合、2005 年 11 月の原系列の値は $133.32 \times 1.1219 \times 0.9977 = 149.2277$ となり、小数点以下 1 桁になおすと 149.2 となる。

完全に値が一致しない理由として、丸め誤差、季節調整値の年合計値の調整のためのウ

ェイト調整に伴うズレ、表にない休日数調整等の推計に伴うものなどがあり得る。

(iii)

2004年12月から2005年1月までの変化率は、原系列で -42% 、季節調整値で -1.9% 、そしてトレンド推計値では $+1.3\%$ となる。

それぞれの推計値が、時系列の動きの特徴を理解する上で有用である。原系列は高い水準から最低の値にまで急減している。しかし、季節調整値は、季節性や祝祭日等に伴う特殊な動きを除いた上での、短い期間でみた動きを示す。トレンドは概括的で緩やかな動きを示す。

(iv)

2005年12月の季節要素をみると 1.4521 である。よって、同月の原系列の水準 (195.77) と季節調整値 ($195.77/1.4521$) を比べた場合、季節調整値が相当低い水準になる。一方、2005年8月の季節要素は 0.9499 であり、原系列の値と比べると季節調整値の方が、むしろ大きくなる。トレンドおよび不規則成分について、2005年8月と2005年12月を比べると、ほぼ同水準である。

(v)

乗法型分解モデルの場合、季節要素の年合計値はほぼ 12 になる必要がある。2005年1月から12月までの季節要素の合計値を計算すると、 $0.8568 + \dots + 1.4521 = 12.0082$ となる。

<2008 年> Module7: Time series and index numbers

Question 1

(i)

復活祭の休日（イースター）は、毎年変動する休日の例になる（このような休日は、世界でもいくつかみられる）。復活祭の休日は、典礼暦（Western Christian calendar）において 3 月 22 日から 4 月 25 日の間になり、多くは 4 月に入る休日である。月次データや特に四半期データの季節調整において、この休日は考慮に入れる必要がある。復活祭では、多くの小売店が特別休暇のため閉店となる。一方、復活祭休日の前の期間は、復活祭関連の特別な商品の売り上げなどが、特殊な動きを示すだろう。復活祭休日が 4 月の場合であっても、その特殊な動きは 3 月になることもあり得る。可能な限り、復活祭の影響を考慮するため、回帰モデルに復活祭の要素を取り込むべきである。

クリスマスは西洋暦では常に 12 月 25 日になる。しかし、この日がどの曜日にあたるかは固定していない。クリスマスにより、最低でも 1 日、たいてい 2 日間は、小売販売店は完全休業となる。12 月は長期にわたり、クリスマス向けの特種な商品、たとえば衣料品、食品、日用品等の売上が増加する。商品によっても動きはことなり、12 月上旬に売り上げ増加が始まるものがある一方、中旬に集中するものもある。よって、商品や調査期間の違いにより、それに応じた異なる扱いをする必要がある。やはり、回帰モデルにクリスマスの要素を取り込むべきである。

(ii)

認識可能な影響の調整は、季節要素の信頼性と質を高めるためのものである。もし、この調整が行われないならば、季節要素の推計値は不十分なものになるだろう。

復活祭の影響の調整における鍵は、3 月と 4 月の変動は相互補完的である点である。この場合、たとえば復活祭前の売上等に影響を与える期間を w 、そのうち 3 月にあたる期間を n_e とした場合、復活祭の回帰変数を 3 月は n_e/w 、4 月は $-n_e/w$ 、その他の月を 0 とする回帰変数で調整する方法が考えられる。

(iii)

季節調整値は、暦に関連した系統的な変動を除去したものであり、トレンド変動および不規則変動のみで構成される。よって、季節調整値は 1 年の中での値の比較が可能である。しかし、非常に大きな不規則変動がある場合、季節調整値は誤った情報を提供してしまう可能性もある。トレンドの場合、時系列データの傾向的な動きを示すものであり、時系列データ内に大きな不規則変動がある場合に、使いやすいものである。しかし、トレンドは、データ端において、データが加わる度に改定されることが欠点である。

分析においては、季節調整値を用いることが大半である。季節調整値は、不規則変動が含まれており、この不規則変動の動きが、(上記の不規則変動の問題点とは別に)、現実世界に起きていることを説明する上で有用な情報を与えてくれる。

Question 2

(i)

回帰のフレームワークを用いる場合、Reg-ARIMAにより原系列をモデル化することが考えられる。ARIMAモデルによる要素の合計をZ、曜日要因の回帰変数をTD(6つの要素の行列)、復活祭の回帰変数をE、2つの外れ値を示す回帰変数をAO1およびAO2とし、これらは加法的になっているとする。すなわち、以下のようになる。

$$Y_t = Z_t + \beta_1(TD)_t + \beta_2(E)_t + \beta_3(AO1)_t + \beta_4(AO2)_t$$

この場合、復活祭、曜日変動および外れ値の影響の大きさの推計値は、季節調整の手順を通じての歪みを受けない。

もし、(原系列ではない)調整済の値に対してモデル化した場合、復活祭、曜日変動および外れ値の影響が、季節調整の一部として扱われ除去される可能性がある。

他に不規則変動をモデル化する手法も考えられるが、フィルターを用いたアプローチを利用している場合、歪みが生じる可能性もあり、必ずしも最善の手段とはならない。この場合、やはり原系列に対してモデル化を行う方が望ましい。

(ii)

診断結果には、t値に対するp値や自由度は与えられていない。そこで、残差(誤差)の自由度は充分であり、t値が2を超えれば5%の有意水準を満たすと仮定する。すると、復活祭および2002年8月の外れ値の影響は(t値の絶対値が2を超えており)モデルに残すべき回帰変数であることがわかる。また、下段にあるカイ二乗検定のp値をみると0.07であり(絶対値が0.05以上であることから)、曜日変動は回帰変数に残す必要はない。

2002年4月の外れ値は(復活祭が3月から4月にかけての期間であることから)、有意と判定された復活祭の影響と関連があると考えられる。この2002年4月の外れ値の回帰変数を除いた新たなモデルで、曜日変動の有意性を改めて確認することも考えられる。

2002年8月および復活祭のt値は負値であることから、両者は対象としている経済データに対して減少に働いていることがわかる。実際に両者が、対象とする経済データに対して減少に働くことの説明がつくか、検討する必要がある。

(iii)

ストックの時系列データの場合、曜日変動や復活祭の影響について頑健な推計結果を得るためには、十分に長期間のデータが必要となる。このため、両者の影響は有意であると判定されにくくなる。

また、復活祭の影響の仕方は経済データの性質に左右されるため、復活祭の回帰変数についても、ユーザー側で適した回帰変数を準備する必要があるかもしれない。

(iv)

一時的な事前調整とは、季節要素を確認（そして除去）するために、実経済等へ与えられた影響を事前に除去するもの。この一時的な事前調整で除去した要素は、季節要素除去後の系列に再び戻される。

一方、恒久的な事前調整とは、暦の変動のような規則的な変動の影響を除去するものであり、（一時的な事前調整とは異なり）季節要素除去後の系列には戻されない。

外れ値に対する一時的な事前調整は、外れ値による実経済への影響は残しながら、同時に外れ値がもたらす季節調整への歪みを無くすために用いられる。しかし、この事前調整を行う際には、調整を行うだけの理由があることが望ましい。

恒久的な事前調整は、規則的な暦の影響に対して適用される。そしてこの影響は、季節調整値には含まれない方が望ましい。本例の場合、復活祭および曜日変動が恒久的な事前調整の対象の候補となる。本例の分析結果では、復活祭は恒久的事前調整の対象として残す必要があるが、曜日効果は不要という結果を示している。

<2009 年> Module7: Time series and index numbers

Question 1

(i)

いくつもの要素が考えられる。例としては以下のものがある。

傾向変動は、長期的で緩やかな変動である。

季節変動は、固定した周期性を持つ変動である。

循環変動は、長期的な繰り返し振幅を伴う変動である。季節変動のような固定した周期性はもたないが、ある程度は予測可能な変動である。

不規則変動は、傾向変動、循環変動、季節変動を除いた変動である。

(ii)

加法型分解モデルにおける季節性の場合、傾向変動にかかわらず季節変動の振幅は固定的である。一方、乗法型分解モデルの季節性の場合、その季節変動の振幅の大きさは傾向変動の影響を受ける。すなわち、傾向変動の水準が高くなるに従い、季節変動の振幅の大きさは拡大する。

モデルによる回帰は加法型の形になるため、モデルの変換は非常に重要になる。たとえば、季節性が乗法型で分散不均一性を示す場合、モデルによる回帰を有効に行うため、対数変換を行う。

(iii)

加法型分解モデルの場合、原系列を X_t 、傾向循環変動を TC_t 、季節変動を S_t とおくと、以下のように分解できる。

$$X_t = TC_t + S_t + \varepsilon_t$$

季節性を除去する方法の一例として、以下のものがある。

(1) 移動平均による TC_t を得る

(2) X_t から TC_t を除去する

(3) 原系列から傾向循環変動を除去した $X_t - TC_t$ の系列を用いて S_t を（タテの移動平均を用いて）推計し、これを原系列から除去する

Question 2

(i)

ARIMA(1 0 1) モデルは、 φ_1 は自己回帰パラメータ、 θ_1 は移動平均パラメータとして、以下のように表される。

$$X_t = \varphi_1 X_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}$$

φ_1 と θ_1 の両パラメータの推計値を、それぞれ $\hat{\varphi}_1$ および $\hat{\theta}_1$ とすると、あてはめ値 \hat{X}_t は以下のように表される。

$$\hat{X}_t = \hat{\varphi}_1 X_{t-1} + \hat{\theta}_1 \varepsilon_{t-1}$$

この時、残差は $X_t - \hat{X}_t$ で表現される。

(ii)

自己相関の強さと性質を確認する最もよい方法はコログラムを見ることである。もし、適切なモデルを適用しているなら、その残差は正規分布となる。そして、自己相関は、どのラグでも平均が0、分散が $1/N$ の正規分布になる。もし、適切なモデルが分からない場合は、信頼区間を用いた推計に頼る必要がある。自己相関が $\pm 2/\sqrt{N}$ （2は標準正規分布の両側5%点である1.96の近似値）を超える場合は0から有意に異なり、モデルが不適切である兆候とされる。一般的にはこれに基づき、 $1/\sqrt{N}$ を残差の自己相関における標準誤差の上限とされる。逆に言えば、モデルが正しくても5%の確率で、自己相関が信頼区間を外れる可能性があることは意識する必要がある。

(iii)

残差を分析する上で、最も単純で原始的な方法は、それを時系列データとしてプロットすることだろう。この方法で、残差の外れ値や周期的なパターンの存在の視覚的な確認ができる。ほかの方法としては、残差に対して下記の指数を算出し、ラグの残差の相関をまとめて考察する方法もある。

$$Q = N \sum_{k=1}^K r_{z,k}^2$$

Nはデータの期間の長さ、Kはラグの数であり通常は15から30程度である。

<2010 年> Module7: Time series and index numbers

Question 1

(i)

加法型分解モデルは、 $Y=C+S+I$ と表現される。そして本モデルの場合、季節調整を行う前に変換を行うべきではない。

乗法型分解モデルは、 $Y=C \times S \times I$ と表現される。そして本モデルの場合、季節調整を行う前に変換を行うべきである。

分解方式を決定する手順としては、以下の方法が考えられる。

まず時系列データに関して事前に得ている情報を利用することが考えられる。時系列データが何らかの差を用いて算出される場合、または時系列データに 0 や負値が含まれる場合は加法型分解モデルが適切である可能性がある。一方、時系列データが指数や経済統計データの場合は、乗法型分解モデルが適切である可能性がある。また、時系列データについて、たとえばデータの構成要素や当該時系列データの過去の期間などの情報を有する場合もある。その場合、構成要素を用いて季節調整で用いるモデルを調整し、(視覚的な診断や定量的な診断により) どのモデルが最善か確認することもできるだろう。

季節調整値は、 $Y=C+I$ または $Y=C \times I$ で表現される。トレンド C を推計、除去するプロセスを経て季節変動成分 S を推計し、原系列から季節変動成分 S を除去することで季節調整値は得られる。この除去において、減算で除去できるのが加法型分解モデルであり、除算で除去できるのが乗法型分解モデルである。

(ii)

押上げにせよ押下げにせよ、復活祭の影響を受ける時系列データにおいては、復活祭時期が 3 月から 4 月の間で変動することは問題を引き起こす。復活祭の影響を受ける時系列データは多く、通常の営業日が減少することにより押下げに働く時系列データもあれば、復活祭に関連する取引により押上げに働く時系列データもある。いずれの場合でも、時系列データの変動は実体のものというよりは、暦の変化により歪められた変動である。たとえば、2 月から 3 月にかけての前期比をある 2 年で比較する場合、復活祭の日数の 3 月と 4 月における配分次第で、その大小関係が変わってしまうこともある。これは時系列データの増減についての判断の誤りをもたらす可能性があり、ユーザーがこの時系列データの動向をもとに判断を行おうとする場合、問題となりえる。

復活祭の影響の有無は、季節調整において復活祭の調整を行った場合と行わない場合の結果を、視覚的または診断により判定することでテストできる。この診断には、復活祭のダミー変数の有意性の推計も含まれる。

もし復活祭の影響があると判定された場合には、季節調整を行う前に復活祭の影響を時

系列データから除去することになる。たとえば、復活祭に伴う変動の半分を復活祭の月から除去し、それを復活祭ではない月に配分することが考えられる。この際、復活祭の調整は永続的調整、すなわち季節調整を行った後も、その調整は残すことに注意する必要がある。

なお、暦に関連した影響を与える要素としては、うるう年や変動休日、たとえばクリスマス、春節、Bank Holiday、ラマダンなどがある。たとえばクリスマスの場合、どの曜日がクリスマスにあたるかにより時系列データに影響する可能性がある。

(iii)

本例の場合、2004年10月および2005年8月の加法的外れ値が有意と確認されている。両者の影響は通常の季節変動では説明できず、また永続的な変化でもなく一時的な振れと考えられる。この2つの外れ値は5%有意であり、両者は季節調整に影響を及ぼすことを示している。一方、復活祭の影響、すなわち3月から4月の期間における復活祭の経年の変動は有意とはなっておらず、復活祭は時系列データには影響を及ぼさないと考えられる。

両外れ値は、外れ値を扱う方針に沿って調整を行う。全外れ値を調整する方針もあれば、実際に何らかの説明が見つかる場合に限定して外れ値を調整する方針もあり得る。なお本例の場合、復活祭については調整すべきでない。

復活祭の調整を永続的調整としたのとは異なり、これらの外れ値への調整は、一時的な調整とし、季節調整を行った後にその調整を元に戻すことになる。

Question 2

(i)

原系列に対する移動平均は、データを平準化し、トレンド成分の初期推定値を得るために利用できる。このトレンド成分の初期推計値を原系列から除去することで、季節・不規則変動成分を得ることができる。この系列を、同一月または四半期のデータを用いた移動平均（タテの移動平均）により平準化することで季節変動要素を得ることができる。この季節変動成分を原系列から除去することで、季節調整値を得ることができる。そして、この季節調整値を用いることで、より精度の高いトレンド成分の推計ができる。

(ii)

2005年第3四半期における5四半期単純移動平均は、以下の式で得られる。

$$\frac{50.0 + 36.5 + 43.0 + 44.5 + 38.9}{5} = 42.58$$

また、他の時点も同様の計算式で算出できる。ただし、この計算はデータの端、すなわち

時系列データの最初の 2 四半期および最後の 2 四半期では実行できない。よって、y の 5 四半期単純移動平均の行を加えた結果は以下ようになる。

商品生産量 y

Period	2005 Q1	2005 Q2	2005 Q3	2005 Q4	2006 Q1	2006 Q2	2006 Q3	2006 Q4	2007 Q1	2007 Q2	2007 Q3	2007 Q4
Production	50.0	36.5	43.0	44.5	38.9	38.1	32.6	38.7	41.7	41.1	40.5	33.8
Moving av.			42.58	40.20	39.42	38.56	38.00	38.44	38.92	39.16		

対称型移動平均は、対象となる時点から同一時点差の値の重みづけを同じものとする、直観的に理解しやすいものである。しかし本例でもわかるとおり、対称型移動平均では、データの端の移動平均値を得ることが出来ない。たとえば本例の場合、もとは 12 時点のデータがあったが移動平均をとることで 8 時点のデータとなってしまっている。対称型移動平均はデータの端では用いることが出来ない。

データの端において平準化した推計値を得るためには、非対称型の移動平均を利用することが考えられる。非対称型の移動平均は、データの利用可能性に応じて、平準化を行う際に用いるデータ数を非対称の配分にして計算される。他の方法としては、モデルによる手法を用いデータを延長推計したうえで、対称型移動平均値を推計する方法が考えられる。

(iii)

単純移動平均は、計算に含まれる全ての時点に同一の重みを持たせることになる。これは、対象とする時点から離れた時点の重みが大きすぎる可能性がある。実際には、より近い時点の影響を受けるだろう。加重移動平均の場合、近い時点の重みを高くしていることから、この点で好ましいものとなる。また加重移動平均は、トレンドの転換点や変曲点を効果的にとらえるための多項式の近似として用いることができる利点もある。

(iv)

一般的に、多くの時点を利用した移動平均は、時点数が多くなるに従い、得られるトレンドをより滑らかにする。しかし時点数を多くする場合には欠点も出てくる。短期間でみた場合、トレンドを線型的と考えても十分によい近似となるが、長期スパンでみた場合にはトレンドが線型的な変化であり続けることはほとんどない。トレンドが変曲する場合、長すぎる時点を利用した移動平均は、トレンド推計値を歪めてしまう。よって、移動平均の時点数は、平準化の度合いと、トレンドの変化の反映のバランスをどうしたいかで決められるべきものである。