

## 放電加工機の時系列解析（中間まとめ）

### 1.1 はじめに

放電加工機の時系列解析に（その1）から（その5）と取り組みました。

今回は、そのレビューです。以下の2点について、まとめます。

- ・データの定常性について、検討します。原系列（元データ）と原系列を変換したもの3点を、グラフとADF検定した結果とで比較します。
- ・今まで、自己回帰モデル、状態空間モデル、非線形非ガウスモデルに、取り組みました。その比較をまとめます。

### 1.2 どのようなデータを扱ったか

放電加工機は、加工中に障害が発生すると自己診断して3段階のレベルに分け、レベルに応じたメッセージを表示します。内容は以下です。

- ・エラーメッセージ：続行不可能な障害が発生したときに表示し、動作を中断する。
- ・ハルトメッセージ：再開可能な障害が発生したときに表示し、一時停止する。
- ・コメントメッセージ：続行可能な障害で発生し、注意を促す。

また、メッセージの記録は、USBによりCSVデータとして取り出すことが可能です。

レベルに対応してデータ処理できるように、3段階のレベルについて障害のレベルが大きいと、点数は大きくなるように点数を設けました。


これらは、メッセージが発生した時の時間毎のデータで、点過程データと呼ばれるもので、時系列データではありません。故に、一日分の平均値を取って時系列データとして取り出すようしました。本データを以下に示します。2022年4月から2023年3月までのデータです。

上段が発生時毎のデータ（点過程データ）で、1年で37000回発生しています。


1点の発生は、一定時間の間隔ではありません。

下段は点過程データを、一日毎に平均して、平均したデータです。点の間隔は1日毎です。時系列データと言えます。

メッセージレベルの発生時データ



メッセージレベルの日別データ



### 1.3 プログラムについて

- ・ ADF 検定 → adfuller

Python の statsmodels というライブラリー内の以下の関数です。

詳細は以下で確認ください。

<https://www.statsmodels.org/stable/api.html#statsmodels-api>

- ・ 推定はカルマンフィルターを用いており、Pykalman ライブラリで計算してます。

本報告書にはプログラムは記載していません。

～参考文献、WEB～

時系列解析 -自己回帰モデル・状態空間モデル・異常検知- 島田直希 著 共立出版(株)

時系列データ分析

<https://qiita.com/tk-tatsuro/items/16ce74fc954b5a58df00>

Python で時系列解析・超入門（その1）

<https://www.salesanalytics.co.jp/datascience/datascience085/>

## 2 データの定常性 について

### 2.1 前処理（変換）の各種方法

時系列データが定常性が無いと判断された場合、データの関係性を正しく解析ができない為、定常性を持たせるための変換を行う必要があります。

定常性とは、期待値（平均値）と自己共分散（バラツキ）が時間を通じて一定であるということで、トレンドを持たないということです。

各種の変換方法を述べます。

#### 1.差分変換

差分変換とは、ある時点  $t$  のときの値とその直前の時点  $t-1$  のときの値の差分  $\delta t = y_t - y_{t-1}$  を計算し、その差を新しいデータとする手法です。1 時点離れたデータとの差を取る手法です。その結果を差分系列、または階差系列と言います。

#### 2.対数変換

対数変換とは、変動が著しく大きな時系列データに対し、対数値変換を施すことで原系列の傾向を保持したまま、値を小さく変換する手法です。

変動の分散を一様にし、複雑な時系列でも変数変換で分析が簡単になることがあります。

対数変換された時系列データは対数系列と呼ばれます。数式では  $\log(y_t)$  と表します。

#### 3.対数差分変換

対数差分変換とは、対数変換と差分変換の両方の変換を施す手法です。

時系列データが変化率や成長率などである場合、対数差分  $\Delta \log(y_t) = \log(y_t / y_{t-1})$  を計算して解析することがあります。

### 2.2 比較の結果


原系列（元データ）と 3 種の変換データをグラフで比較し、次に ADF 検定という、定常性を判定する関数があるので、結果を比較します。

まずグラフについての考察ですが


平均値が一定であるもの、ばらつきが少ないものが、適切ですが、

4 個のグラフ間では、あまり差がなく、差分変換したものが、平均値は一定のように見えます。


原系列



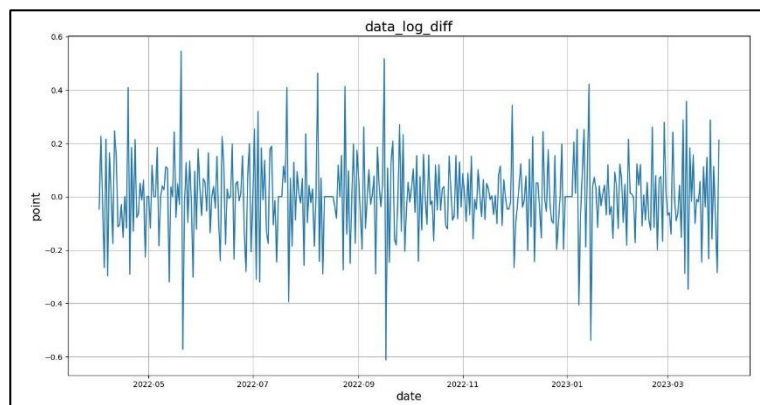
差分变换



对数变换



对数差分变换



次に、下の表が ADF 検定の結果です。

定常性があると判定できるのは

- ・ 検定統計量が、棄却値 5% の値より小さいこと
- ・ p 値が 0.05 以下であること

とされており、原系列も他の点の変換例も定常性ありと言えます。

	原系列	差分	log	log 差分
平均	1.200760631	-0.0003071	0.174702661	-0.000266268
分散	0.025515416	0.043376275	0.016170783	0.026269714
adf 検定統計量	-10.62998848	-8.840497998	-10.04156452	-8.169681629
p	5.24E-19	1.67E-14	1.49E-17	8.69E-13
棄却値 1%	3.448493651	3.449011444	3.448493651	-3.44911857
棄却値 5%	-2.869535228	-2.869762707	-2.869535228	-2.869809765
棄却値 10%	2.571029334	2.571150616	2.571029334	-2.571175706

先回の検討でも 原系列でも定常性は有りの判定でしたが、  
同じ結果になりました。

### 3 取り組んだモデルの比較

自己回帰モデル、状態空間モデル、非線形非ガウスモデルについて、取り組んだので、比較してみます。

ざっくり言うと、時系列データには、以下の3回のアプローチで行います。

- ・統計モデルの「型」を決めます。（人がやります）
- ・学習データを用いて、推定します。  
(推定法には、最尤法、カルマンフィルタ等があります)
- ・予測します。(予測の評価として、テストデータと比較します)

#### 3.1 自己回帰モデル

AR モデル、SARIMA モデル に取り組みました。

- ・型について

AR モデルは以下で表します。

$$y_n = \sum_{i=1}^m a_i y_{n-1} + v_n \quad m \text{ は次数 } a_i \text{ は係数 です。}$$

SARIMA モデルの型は説明が難しいです。

AR モデル = 自己回帰モデル (時間の変化に規則的に値が変化)

MA モデル = 移動平均モデル (時間の変化に不規則的に値が変化)

ARIMA モデル = ARMA の差分モデル (差分をデータとします)

SARIMA モデル = 周期的変動 (季節成分) を加えたモデル

という モデルの構成で表します。

SARIMA モデルを数式で表すると、以下ですが、分かりにくいです。

ARIMA モデルまでは、加法ですが、ここは乗法となります。

$\Delta^d$  は ARIMA 過程の差分で、 $\Delta_s^D$  は 季節階差の差分です。

$$\Phi(B)\Phi_s(B)\Delta^d\Delta_s^D y_t = \theta(B)\theta_s(B) \varepsilon_t$$

$$\Phi(B) = 1 - \sum_{i=1}^p \phi_i B^i \quad \Phi_s(B) = 1 - \sum_{i=1}^P \phi_{si} B^{si}$$

$$\theta(B) = 1 + \sum_{i=1}^q \theta_i B^i \quad \theta_s(B) = 1 + \sum_{i=1}^Q \theta_{si} B^{si}$$

$$B^n = y_{t-n} / y_t \text{ (バックシフト演算子)}$$

詳細は、参考文献で確認ください。

- ・推定について、  
次数は予め設定し（AIC で判定することもできますが、経験的に差はそれほどありません）、係数は最尤法（最小二乗法）で求めます。
- ・予測について、  
季節成分を加味した SARIMA モデルが、優れます。

特徴的なこととして、自己回帰モデルにおいては、学習データの推定時において、実データと推定データの乖離があります。実データは、ある確率分布に従う真のデータの確率変数の実現値ですので、推定データは、確率分布の期待値（平均値）と考えれば、当然かもしれませんが、状態空間モデルのカルマンフィルタは逐次推定で、推定値は学習データから外れないので、両者間の差を感じます。

### 3.2 状態空間モデル

トレンド傾向、季節傾向、AR 傾向を加味したモデルが良好な結果となります。

- ・型について、  
時系列データを、トレンド成分（時間とともに単調に増加/減少する変動）と季節成分（同じ周期で規則的に繰り返される変動）と不規則成分との合計と考え、不規則成分は、AR モデルに準じると考えます。

数式で表すと以下です。  $y_n$  は 観測データです。

$$\begin{aligned}
 y_n &= t_n + s_n + r_n + w_n & w_n &\sim N(0, \delta^2) \\
 t_n &= \sum_{i=1}^k c_i^{(k)} t_{n-i} + v_{n1} & v_{n1} &\sim N(0, \tau_1^2) && \text{トレンド成分} \\
 s_n &= -\sum_{i=1}^{p-1} s_{n-i} + v_{n2} & v_{n2} &\sim N(0, \tau_2^2) && \text{季節成分} \\
 r_n &= \sum_{i=1}^q \phi_i r_{n-1} + v_{n3} & v_{n3} &\sim N(0, \tau_3^2) && \text{AR 成分}
 \end{aligned}$$

トレンド成分は、傾きは無いとして、次数を 1 としました。係数は 1 です。

季節成分は、月単位の変化を想定して、次数を 30 としていたのですが、

現状は月単位、週単位でもないので、グラフの周期から、次数は、4 としました。

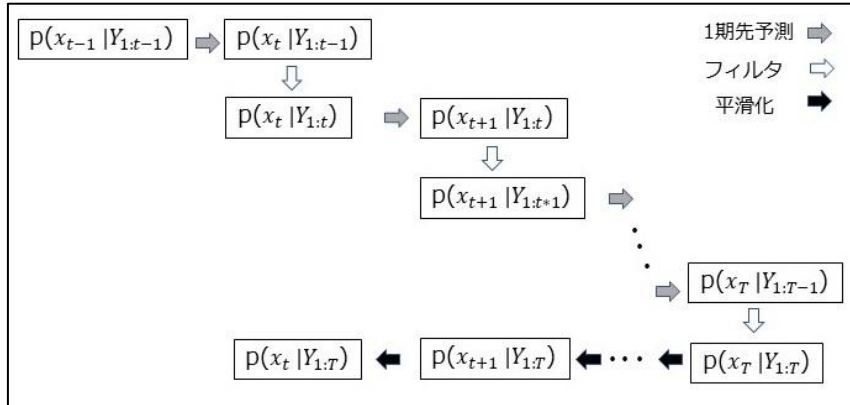
AR 成分は、次数を 2 としました。



- ・推定について、

カルマンフィルタで計算しますが、ライブラリは Pykalman を用いています。

詳細は、先回に記載したので、説明図のみ、表示します。



状態空間モデルのカルマンフィルタは逐次推定で、学習データについては、推定値は、はずれません。

### 3.3 非ガウス非線形モデル

非ガウス型の近似には、色々な手法がありますが、今回は、粒子フィルターで、行います。

- ・型について

確率分布を点の集まりとして近似します。密度関数の高いところに多くの粒子が集中します。粒子の集中度合いを、実測値と比較して、フィルタリングとサンプリングを繰り返します。式は以下のような 簡単な数式です。

$$x_t = F_t (x_{t-1} , v_t) \quad \text{状態関数}$$


$$y_t = H_t (x_t , w_t) \quad \text{観測関数}$$

- ・推定について


粒子フィルターにより行います。(カルマンフィルタに似てます)

## 4 結果


### 4.1 SARIMAモデルの 推定値 と 予測（黒線） です。



### 4.2 状態空間モデルの 推定値と予測です。



#### 4.3 非ガウス非線形モデルの 推定値と予測です。



#### 5 まとめ

- 推定、予測について、状態空間モデルが優位でした。
- モデルは、季節成分（循環成分）を加えて、計算する方が優位でした。
- 今後も、継続検討します。