

時系列 (後半)

国際文化学部 1236573c 竹内 信吾

12.6 ARMA/ARIMAモデル

時系列データに適用されるモデルの一つ

自己回帰モデル (AR)に誤差の移動平均を加えたモデルを

自己回帰移動平均 (ARMA : AutoRegressive Moving average)モデルと呼ぶ

$$y_t = \sum_{i=1}^p a_i y_{t-i} + e_t + \sum_{j=1}^q b_j e_{t-j}$$

y_t の d 階の差分演算子 $\Delta^d y_t$ のARMAモデルを、自己回帰和分移動平均 (ARIMA : AutoRegressive Integrated Moving Average) モデルと呼び

ARIMA(p,d,q)で表す。

12.6.2 関数arimaとモデルの推定

パッケージstatsには、
単変量時系列データを当てはめるARIMAモデル関数arimaがある。

```
> arima
function (x, order = c(0L, 0L, 0L), seasonal = list(order = c(0L,
  0L, 0L), period = NA), xreg = NULL, include.mean = TRUE,
  transform.pars = TRUE, fixed = NULL, init = NULL, method = c("CSS-ML",
  "ML", "CSS"), n.cond, SSinit = c("Gardner1980", "Rossignol2011"),
  optim.method = "BFGS", optim.control = list(), kappa = 1e+06)
```

引数 x は、時系列データオブジェクトであり、 $order$ は自己回帰の次数 p 、
差分の階数 d 、過去の残差の移動平均の次数 q を指定する引数である。

☆ データlhを用いた、arima(2,0,1)の例

```
> (lh.ari<-arima(lh,order = c(2,0,1)))
```

```
Call:
```

```
arima(x = lh, order = c(2, 0, 1))
```

```
Coefficients:
```

	ar1	ar2	ma1	intercept
	1.1765	-0.5044	-0.5080	2.3946
s.e.	0.3990	0.2190	0.4517	0.0944

```
sigma^2 estimated as 0.1827: log likelihood = -27.6, aic = 65.2
```

返された係数 (coefficients)を,ARIMA(2,0,1)モデルに用いると、

$$y_t = 2.3946 + 1.1765y_{t-1} - 0.5044y_{t-2} - 0.508e_{t-1} + e_t$$

12.6.3 モデルの選択

関数`arima(p,d,q)`における引数`order`の`p,d,q`の値を決める一つの方法は、ある範囲内の`p,d,q`のすべての組み合わせの中から、情報量基準（AICやBICなど）値が最も小さい組み合わせを用いる方法である。

```
> data<-lh; T<-0
> for(p in 1:4)
+   for(d in 0:1)
+     for(q in 0:4){
+       fit<-arima(data,order=c(p,d,q))
+       T<-T+1
+       if(T==1){
+         minaic<-fit$aic
+         orderP<-p; orderD<-d; orderQ<-q;
+       }else{
+         if (fit$aic<minaic){
+           minaic<-fit$aic;
+           orderP<-p; orderD<-d; orderQ<-q;
+         }
+       }
+     }
+ }
> cat("RESULT: p=",orderP,"d=",orderD,"q=",orderQ,"AIC=",minaic,"\n")
RESULT: p= 3 d= 0 q= 1 AIC= 64.75832
```

求めたp,d,qはそれぞれ3,0,1であるので

```
> (lh.ari<-arima(lh,order = c(3,0,1)))
```

Call:

```
arima(x = lh, order = c(3, 0, 1))
```

Coefficients:

	ar1	ar2	ar3	ma1	intercept
	-0.0608	0.4170	-0.3596	0.7758	2.3923
s.e.	0.1979	0.1415	0.1398	0.1795	0.1056

```
sigma^2 estimated as 0.1713: log likelihood = -26.24, aic = 64.47
```

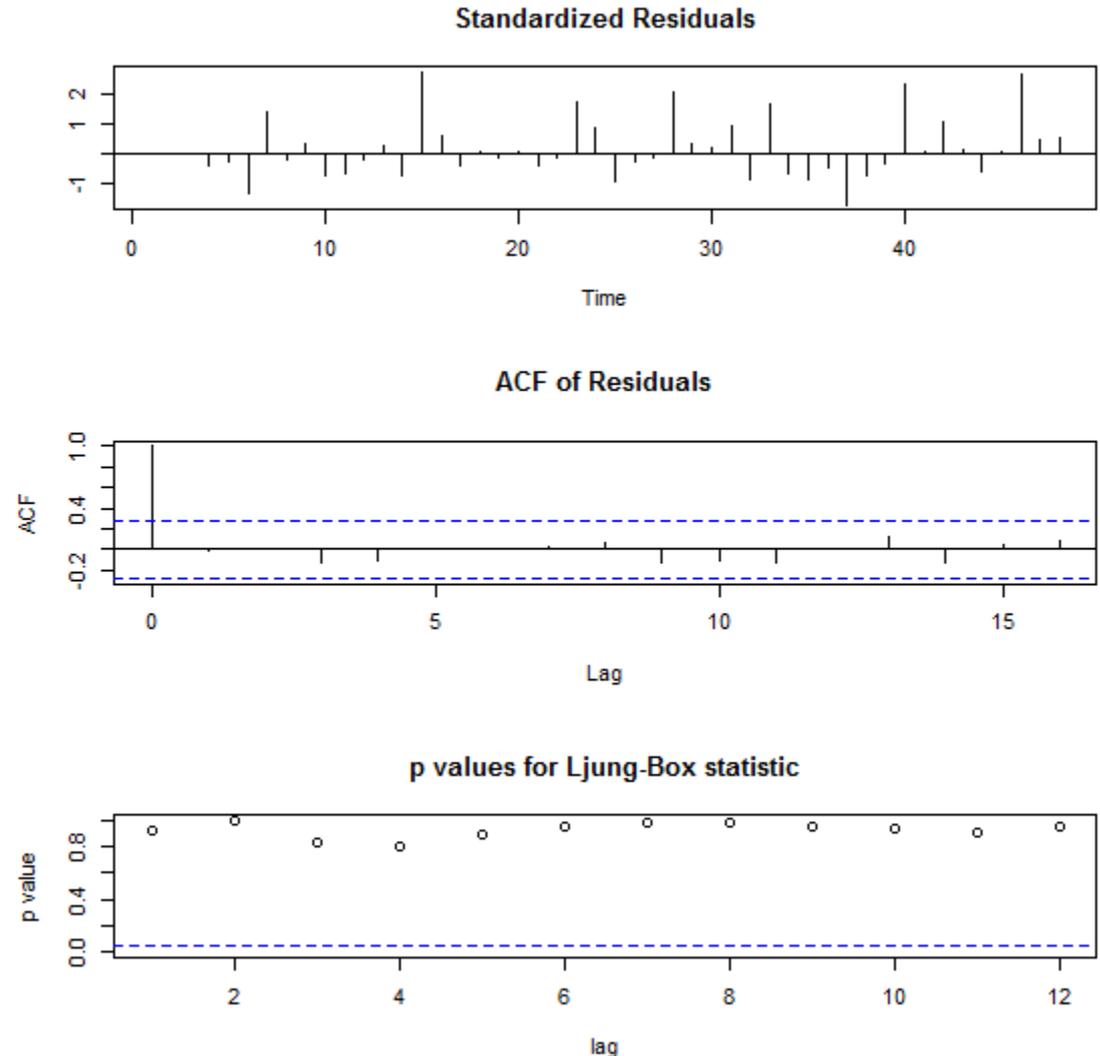
返される結果を小数点以下3桁まで丸めたARIMA(3,0,1)を示すと以下のように示される

$$y_t = 2.392 - 0.061y_{t-1} + 0.417y_{t-2} - 0.360y_{t-3} + 0.776e_t$$

☆ 関数 *tsdiag*

ARIMAモデルを診断(残差分析)するツールとして関数*tsdiag*がある。データ*lh*のARIMA(3,0,1)モデルの診断図を次に示す。診断図の上部は、残差のプロット、中部は残差の自己相関のプロット、下部は引数*gof.lag*に対応するLjung-Box検定のp値のプロットである。

```
> tsdiag(fit,gof.lag=12)
```



12.7.1 ARIFIMAモデル

ARIMAモデルでは過剰の差分が起こり得ると指摘されている。その短所を克服するため、差分の階数 d が整数に限らず、任意の実数に一般化した方法を自己回帰実数積分移動平均 (**ARFIMA**: *AutoRegressive Fractionally integrated moving Average*) と呼ぶ

ARFIMA分析の専用パッケージとして **fracdiff** がある

☆航空会社の1949年から1960年までの国際旅客数に関する時系列データ

```
> (AP.d<-fdGPH(AirPassengers)$d)
[1] 0.6513916
> AP.fra<-fracdiff(AirPassengers,nar=3, dtol= AP.d,nma=1)
> summary(AP.fra)
```

Call:

```
fracdiff(x = AirPassengers, nar = 3, nma = 1, dtol = AP.d)
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)	
d	4.604e-01	1.442e-01	3.192	0.00141	**
ar1	-1.159e-02	5.996e-05	-193.222	< 2e-16	***
ar2	3.295e-01	3.103e-01	1.062	0.28826	
ar3	-1.266e-01	7.667e-05	-1650.804	< 2e-16	***
ma	-9.009e-01	1.197e-01	-7.527	5.2e-14	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

sigma[eps] = 29.69193

[d.tol = 0.1, M = 100, h = 7.322e-06]

Log likelihood: -693.9 ==> AIC = 1399.788 [6 deg.freedom]

12.7.2 GARCHモデル

時系列データが、条件付き平均 g_t 、条件付き分散 h_t の正規分布 $N(g_t, h_t)$ に従うとき、 h_t の変動を

$$h_t = \omega + \sum_{i=1}^q \alpha_i e_{t-i}^2$$

で表現するモデルを自己回帰条件付き分散不均一(ARCH: Autoregressive Conditional Heteroscedastic) モデルと呼び、通常 ARCHモデルと呼ぶ。式の中の ω は定数である。

さらに、ARCHモデルを次のように拡張したものを GARCH(Generalized ARCH)モデルと呼ぶ。

$$h_t = \omega + \sum_{i=1}^q \alpha_i e_{t-i}^2 + \sum_{j=1}^r \beta_j h_{t-j}$$

☆ Garchfit関数を用いた分析 パッケージfGarchを用いる

```
> UKg.d<-diff(UKgas)
> UKg.m<-garchFit(fomula=~arma(1,1)+garch(1,1),data=UKg.d,trace = F)
> summary(UKg.m)
```

```
Title:
  GARCH Modelling
```

```
Call:
  garchFit(data = UKg.d, trace = F, fomula = ~arma(1, 1) + garch(1,
    1))
```

```
Mean and Variance Equation:
  data ~ garch(1, 1)
<environment: 0x0000000009794398>
 [data = UKg.d]
```

```
Conditional Distribution:
  norm
```

```
Coefficient(s):
      mu      omega      alpha1      beta1
 8.29002 275.31909 0.44795 0.60021
```

```
Std. Errors:
  based on Hessian
```

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)	
mu	8.2900	6.8918	1.203	0.22902	
omega	275.3191	446.4387	0.617	0.53743	
alpha1	0.4479	0.1571	2.852	0.00435	**
beta1	0.6002	0.1298	4.623	3.78e-06	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:

-684.3691 normalized: -6.395973

Description:

Fri Aug 08 09:43:40 2014 by user: 1236573c

Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi ²	7.677948	0.02151566
Shapiro-Wilk Test	R	W	0.9282948	2.196842e-05
Ljung-Box Test	R	Q(10)	433.5541	0
Ljung-Box Test	R	Q(15)	586.1374	0
Ljung-Box Test	R	Q(20)	794.2856	0
Ljung-Box Test	R ²	Q(10)	170.0033	0
Ljung-Box Test	R ²	Q(15)	197.6151	0
Ljung-Box Test	R ²	Q(20)	209.9766	0
LM Arch Test	R	TR ²	48.77365	2.291151e-06

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
12.86671	12.96663	12.86405	12.90722

情報量基準は@fit\$ics,残差は@residuals,当てはめ値は@fitted.valuesで返すことができる

例) 情報量基準(@fit\$ics)を求める

```
> UKg.m@fit$ics
      AIC      BIC      SIC      HQIC
12.86671 12.96663 12.86405 12.90722
```

関数garchFitの結果を関数plotに代入すると、13種類のグラフを作成することができる。関数plotを実行すると、作成可能なグラフのリストを返す。「選択(Selection):」の右にグラフの種類番号を入力し、Enterキーを押す。

```
> plot(UKg.m)
```

```
Make a plot selection (or 0 to exit):
```

```
1: Time Series          2: Conditional SD      3: Series with 2 Conditional SD Superimposed
4: ACF of Observations 5: ACF of Squared Observations 6: Cross Correlation
7: Residuals           8: Conditional SDs    9: Standardized Residuals
10: ACF of Standardized Residuals 11: ACF of Squared Standardized Residuals 12: Cross Correlation between r^2 and r
13: QQ-Plot of Standardized Residuals
```

```
Selection: 1
```

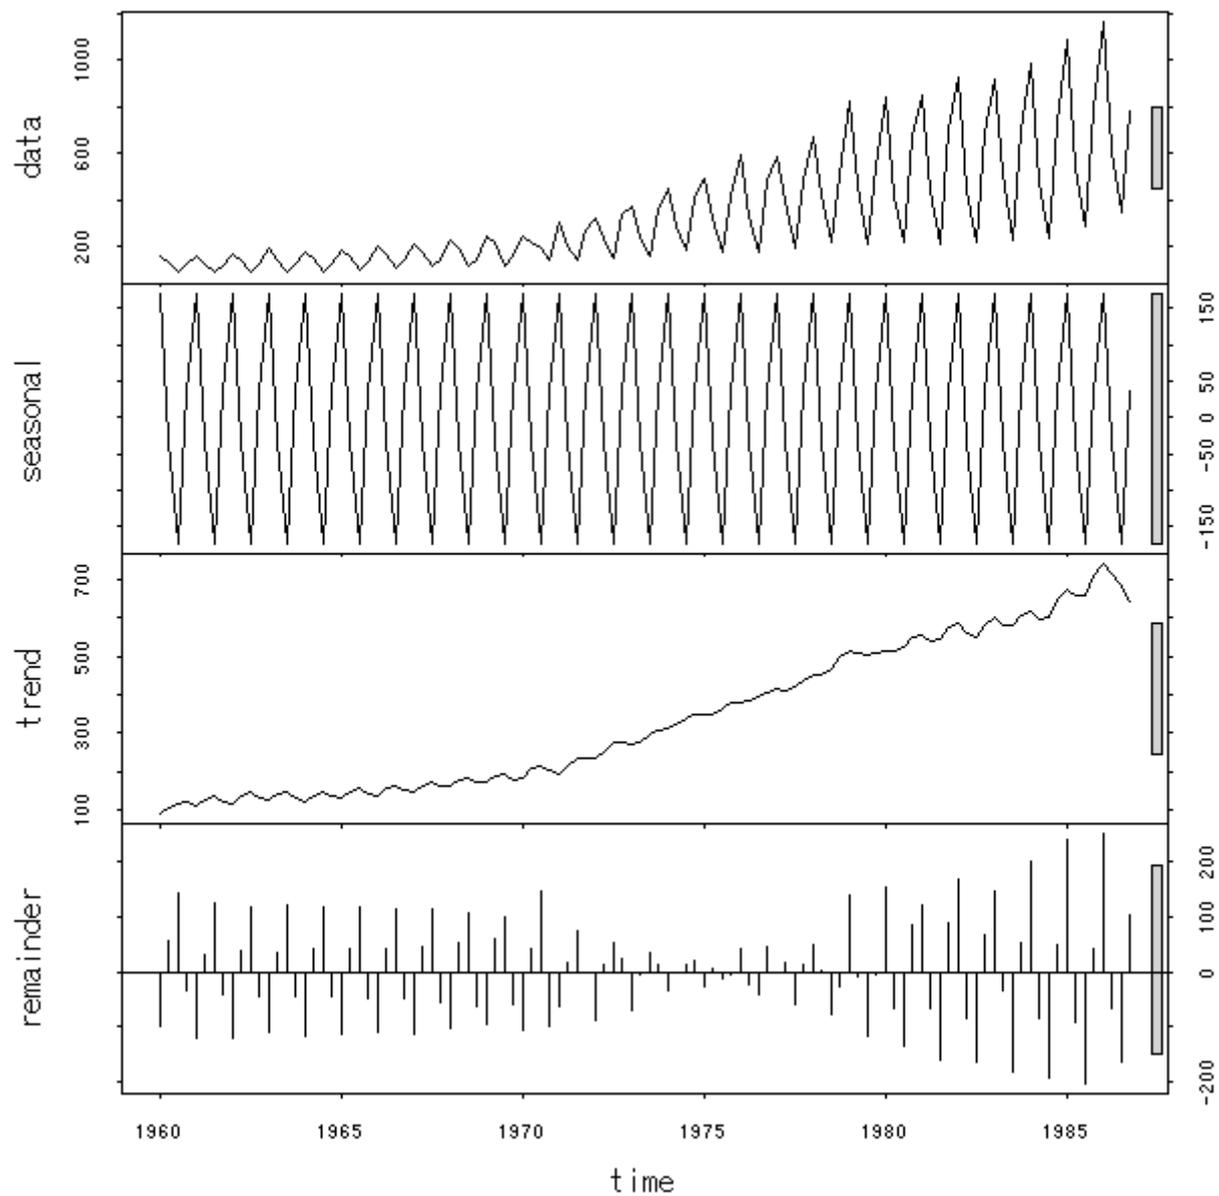
12.8 成分の分解

時系列データには、周期的に変動する周期性質を持つものも少なくない。一定の期間で周期的に変動する時系列データについて、それを幾つかの成分に分解することによって、より詳細に分析を行うことができる。

典型的な例として次のモデルがある。

観測値 = トレンド + 周期変動 + 残差

```
> plot(stl(UKgas, s.window = "per"))  
> |
```



成分ごとのプロット

12.9 多変量時系列

多変量時系列解析に関しては、最も多く知られているのはベクトル自己回帰 (VAR:Vector AutoRegressive)モデルである。

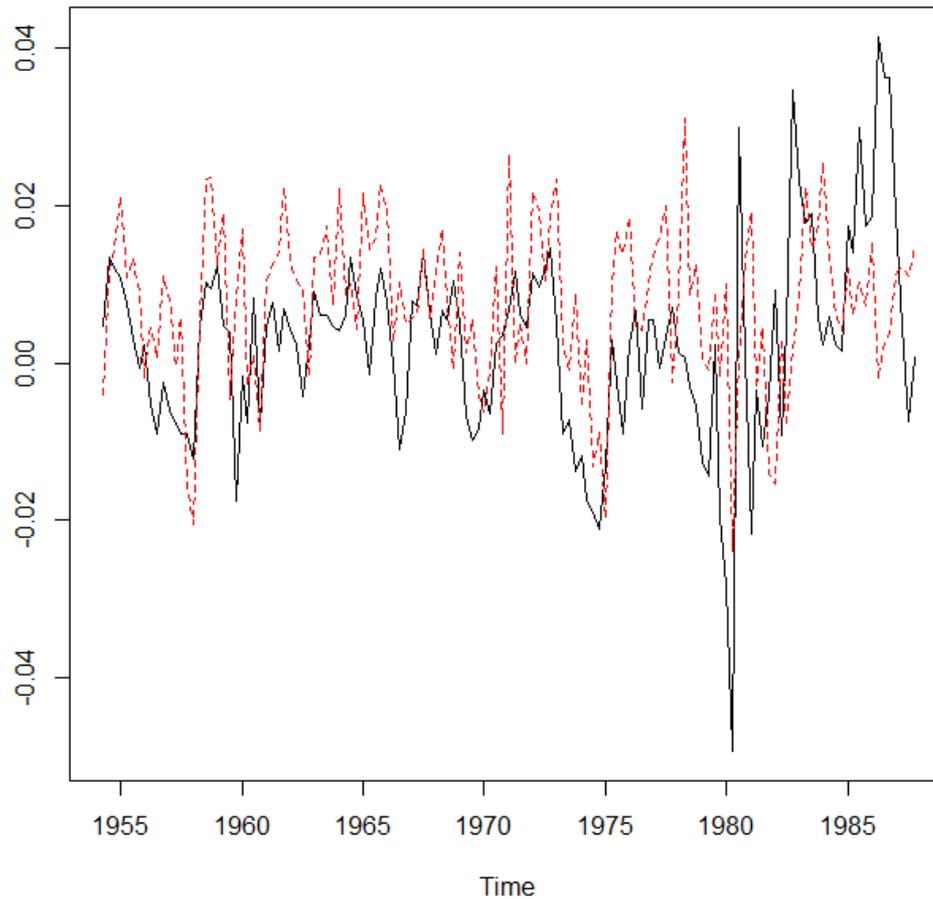
$$Y_1, \dots, Y_{t-p}, \dots, Y_t, \dots, Y_{t+p}, \dots, Y_n$$

とすると、VARモデルは次のように定義される

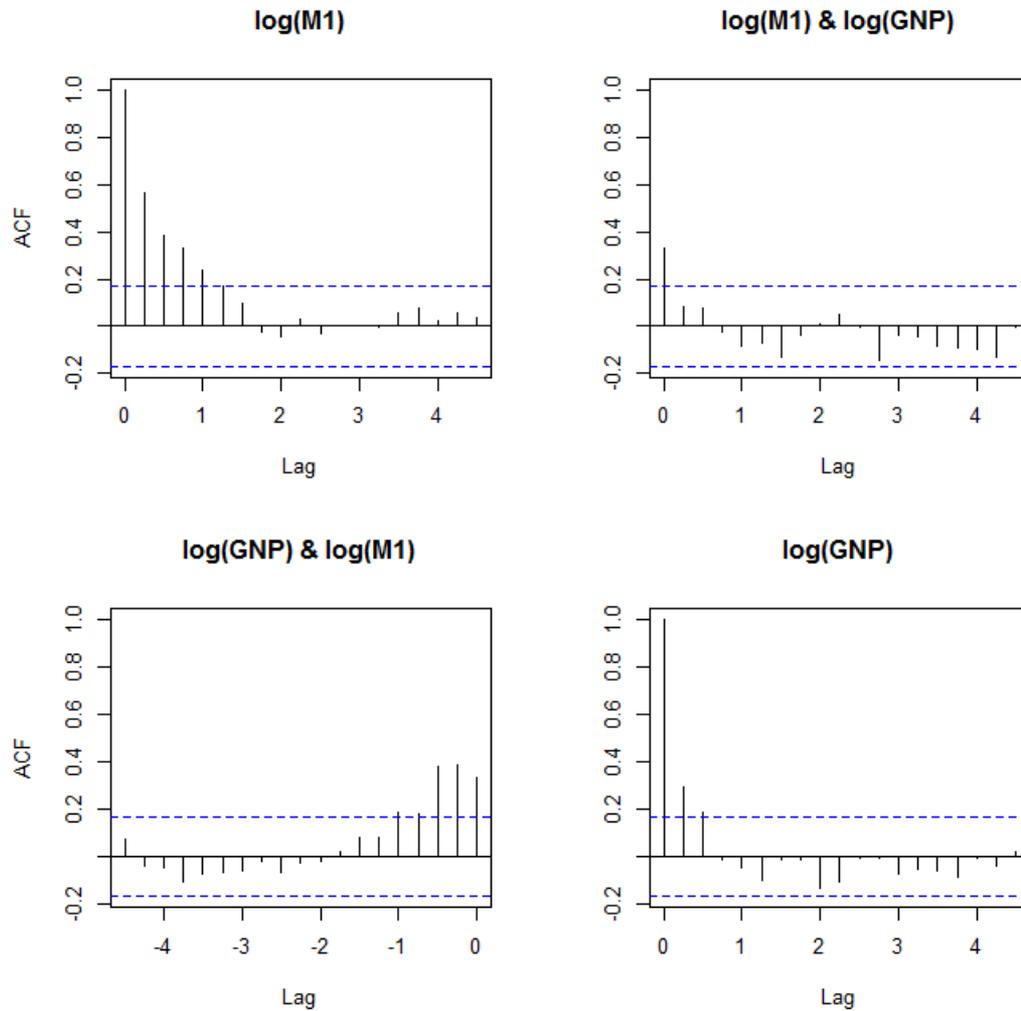
$$Y_t = A_1 Y_{t-1} + \cdot \cdot \cdot + A_p Y_{t-p} + E_t$$

☆経済時系列データUSEconomicを用いた解析

```
> library(tseries);data(USEconomic)
> USE.d<-diff(USEconomic[,1:2])
> ts.plot(USE.d,lty=c(1,2),col=c(1,2))
> legend(locator(1),c(colnames(USE.d)[1],colnames(USE.d)[2]),
```

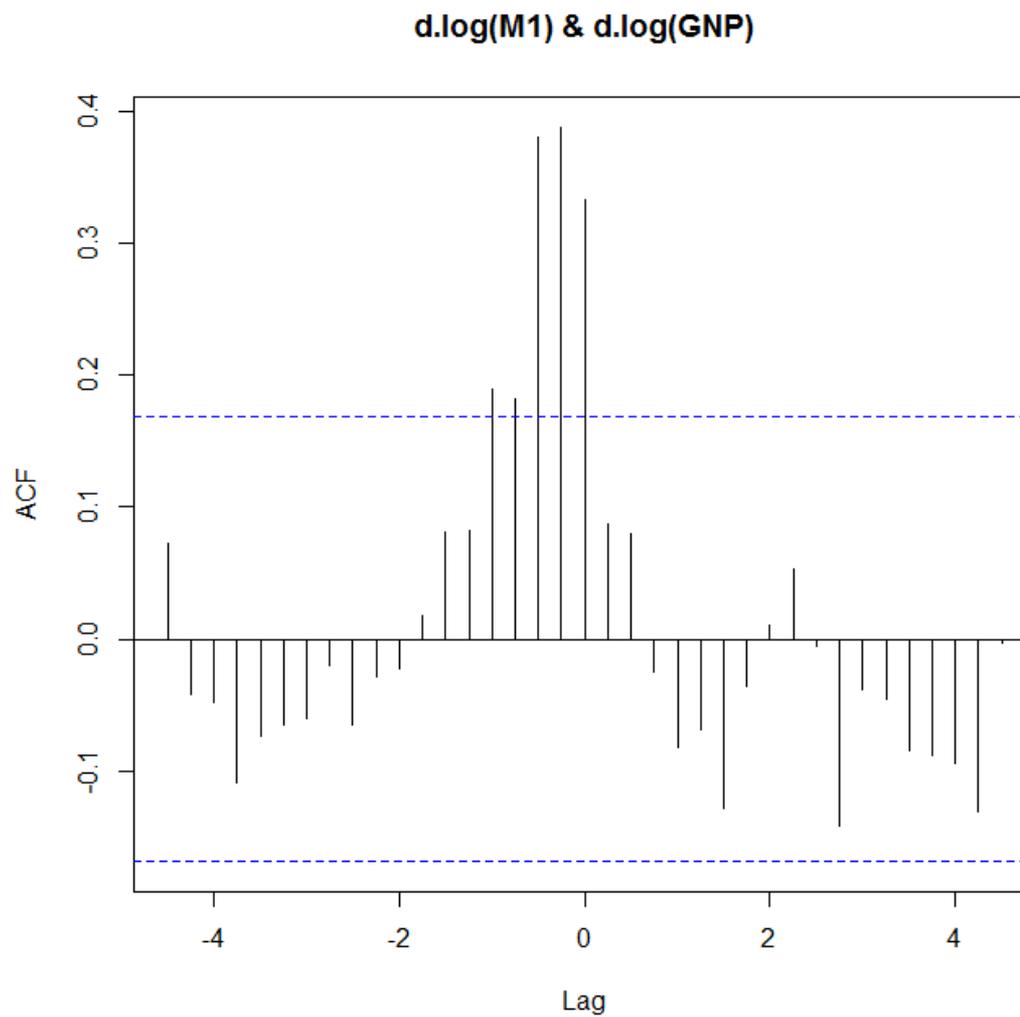


```
> acf(USE.d,na.action=na.pass)
>
```



自己相関プロット

```
> ccf(USE.d[,1],USE.d[,2],main="d.log(M1) & d.log(GNP)")  
> (USE.ar<-ar(USE.d,order.max=2,aic=F))
```



相互相関プロット

```
> (Use.ar<-ar(Use.d,order.max=2,aic=F))
```

```
Call:
```

```
ar(x = Use.d, aic = F, order.max = 2)
```

```
$ar
```

```
, , 1
```

	log(M1)	log(GNP)
log(M1)	0.5446	-0.1888
log(GNP)	0.1981	0.1295

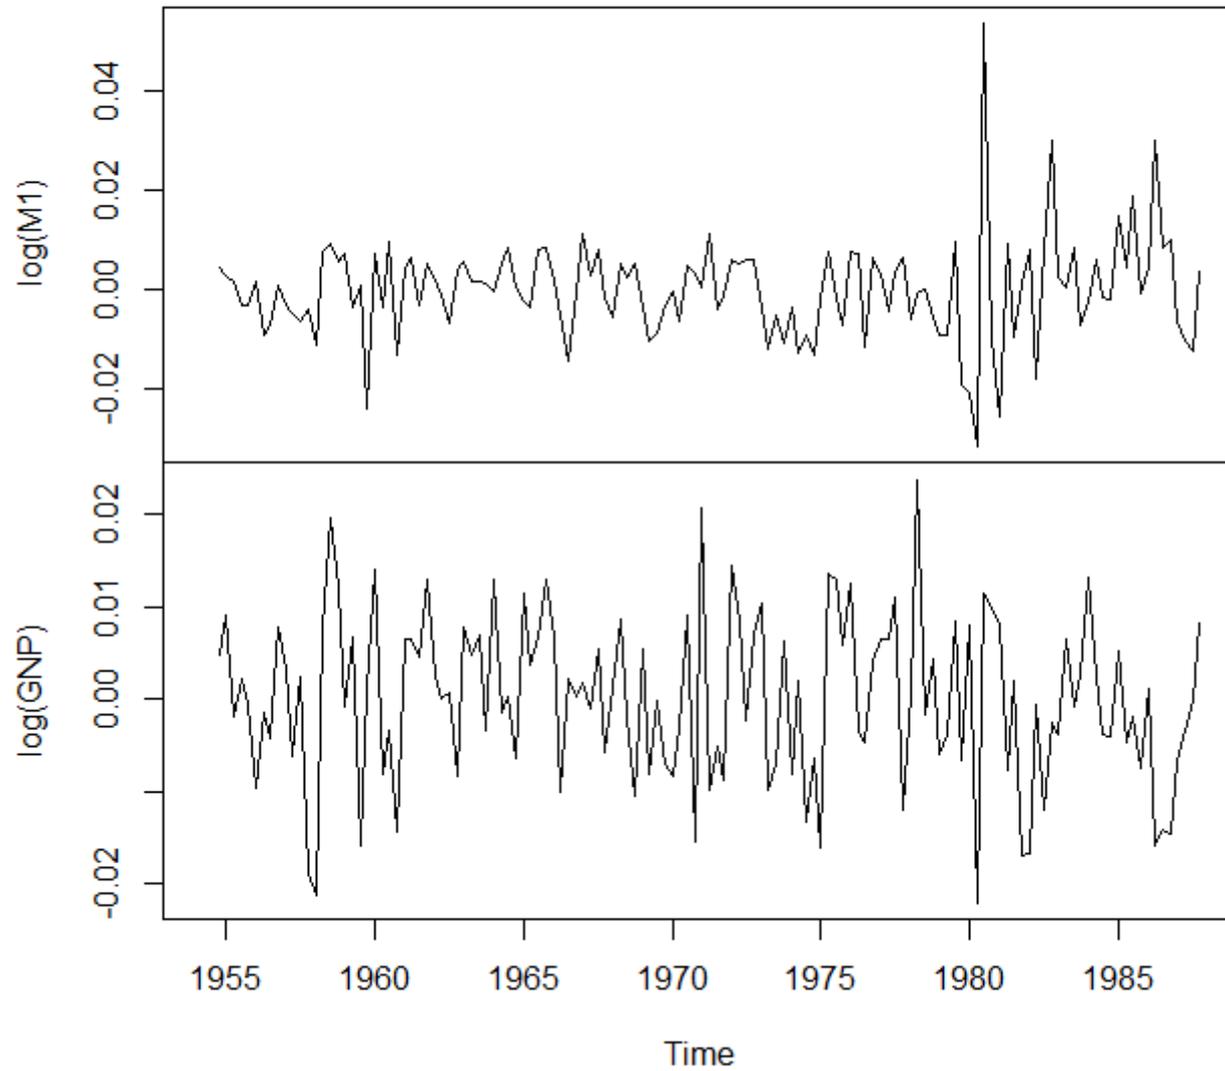
```
, , 2
```

	log(M1)	log(GNP)
log(M1)	0.1231	0.04513
log(GNP)	0.1371	0.07110

```
$var.pred
```

	log(M1)	log(GNP)
log(M1)	1.063e-04	1.506e-05
log(GNP)	1.506e-05	8.494e-05

USE.ar\$res



VAR(2)モデルの残差のプロット

12.10 カオス時系列

不規則に変動する時系列データを非線形に解析する手法として、カオス理論に基づいた方法がある。

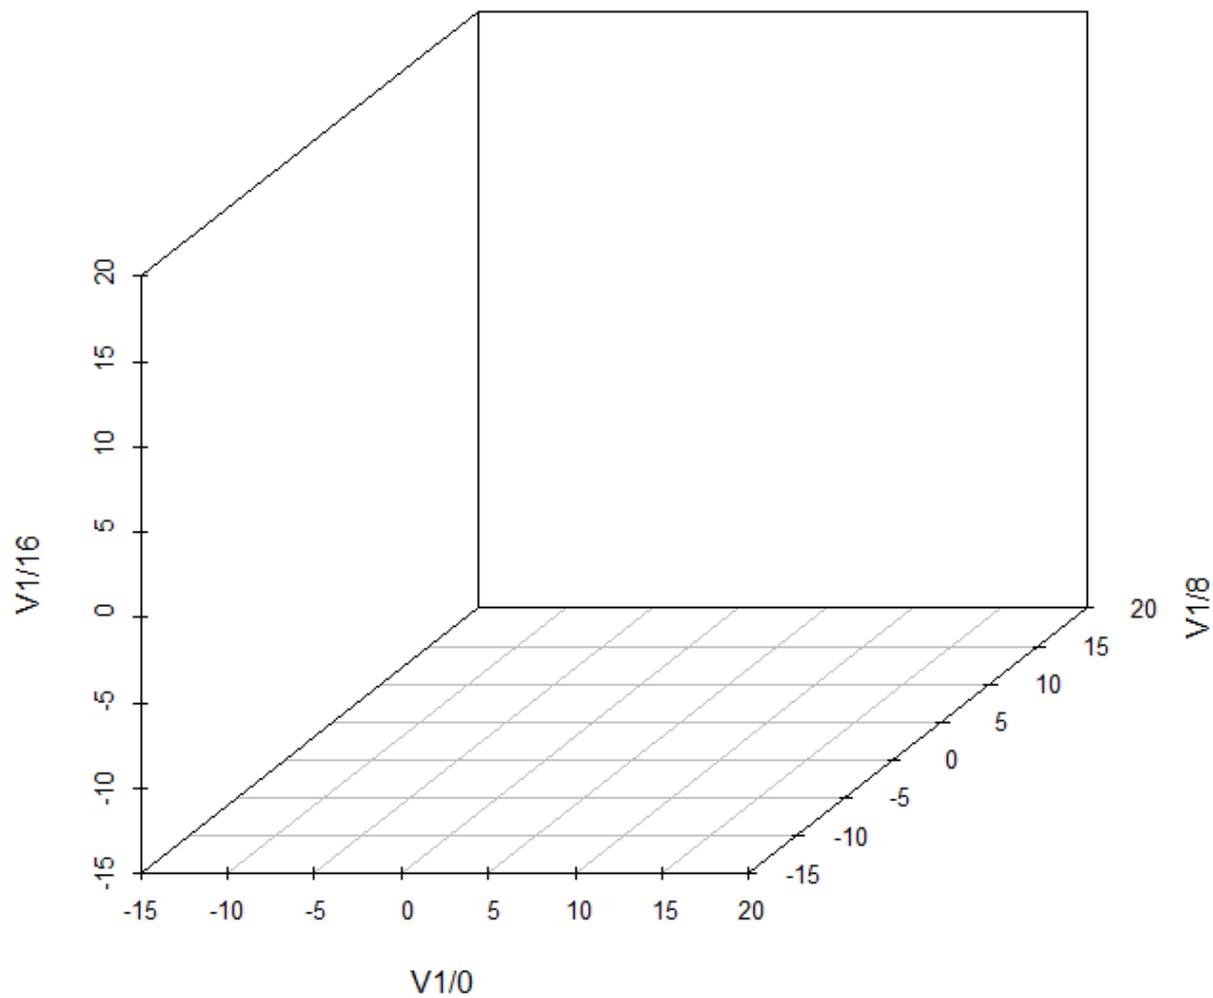
Rには、カオス時系列解析のためのパッケージ *tseriesChaos* がある

時系列データ `rossler.ts` を関数 `emded` を用いて3次元に埋め込み (embedding), 3次元空間を図示する。

初めにパッケージ *tseriesChaos* と *Scatterplot3d* をダウンロードする

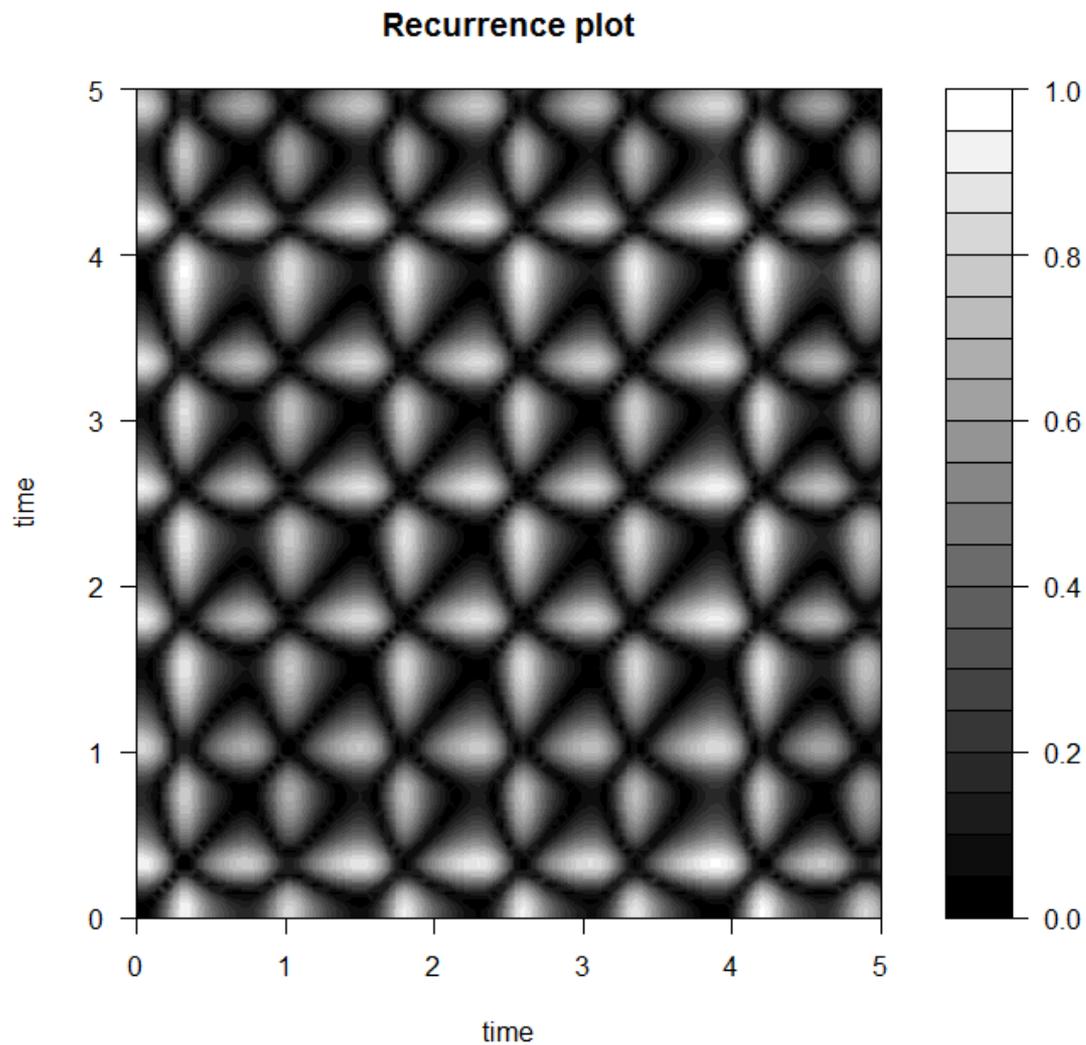
```
> install.packages("tseriesChaos"); library(tseriesChaos);  
> install.packages("scatterplot3d"); library(scatterplot3d)
```

```
> library(scatterplot3d)
> recurr(lorenz.ts, m=3, d=0, start.time=10, end.time=15)
> |
```



埋め込み3次元プロット

```
> recurr(lorenz.ts, m=3, d=0, start.time=10, end.time=15)  
> |
```



リカレンスプロットの例