

Tendência e Sazonalidade

Lane Alencar
2016

Componentes

- ▶ Podemos decompor o processo

$Z = \{Z(t), t \in T\}$ em:

- ▶ $Z_t = T_t + S_t + a_t$ com

- ▶ T_t : tendência

- ▶ S_t : componente sazonal

- ▶ a_t : erro aleatório com $E(a_t) = 0$ e $\text{Var}(a_t) = \sigma^2$.

Tendência: $Z_t = T_t + a_t$

Métodos para estimar T_t

- ▶ Polinômio:
- ▶ Suavizar os valores da série para estimar a tendência em cada instante;
- ▶ Suavizar a série com ajustes sucessivos de retas de mínimos quadrados (lowess);
- ▶ Após estimar T_t podemos obter a série livre de tendência $Y_t = Z_t - \hat{T}_t$.

Polinômio

- ▶ Supomos $T_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \dots + \beta_p t^p$. Ajustando o polinômio pelo método de mínimos quadrados temos que minimizar

$$\sum_{t=1}^T (Z_t - \beta_0 - \beta_1 t - \beta_2 t^2 - \dots - \beta_p t^p)^2$$

Polinônio + sen + cos

```
# Mortalidade cardiovascular semanal de 1970 a 1979
install.packages("astsa")
library(astsa)
plot(cmort, main="Cardiovascular Mortality", xlab="", ylab="")
tempo = 1:length(cmort)
tempo2 = tempo^2
tempo3 = tempo^3
c = cos(2*pi*tempo/52)
s = sin(2*pi*tempo/52)
fit1 = lm(cmort ~ tempo + tempo2 + tempo3)
fit2 = lm(cmort ~ tempo + tempo2 + tempo3 + c + s)
plot(tempo, cmort)
lines(fit1$fit)
lines(fit2$fit)
```

Médias Móveis

- ▶ Médias móveis em torno de Z_t

$$Z_t^* = \frac{1}{2n+1} \sum_{j=-n}^n Z_{t+j}.$$

- ▶ De modo mais geral:

$$Z_t^* = \sum_{j=-n}^n c_j Z_{t+j}.$$

Médias Móveis $Z_t = T_t + a_t$

- ▶ Médias móveis em torno de Z_t

$$\begin{aligned} Z_t^* &= \sum_{j=-n}^n c_j(T_{t+j} + a_{t+j}) \\ &= \sum_{j=-n}^n c_j T_{t+j} + \sum_{j=-n}^n c_j a_{t+j}, \end{aligned}$$

- ▶ vamos denotar

$$a_t^* = \sum_{j=-n}^n c_j a_{t+j}.$$

Médias Móveis

Supondo

- ▶ $E(a_t) = 0$
- ▶ Tendência suave:

$$E(Z_t^*) = \sum_{j=-n}^n c_j T_{t+j} \approx \sum_{j=-n}^n c_j T_t = T_t = E(Z_t).$$

- ▶ $Var(a_t^*) = \sigma^2 \sum_{j=-n}^n c_j^2$ e para $\sum c_j^2 < 1$, temos $Var(a_t^*) < Var(a_t)$ e consequentemente $Var(Z_t^*) < Var(Z_t)$.

Médias Móveis

- ▶ Introduzimos correlação nos erros.
- ▶ Supondo $\text{Cov}(a_t, a_s) = 0, s \neq t$, obtemos:

$$\text{Cov}(a_t^*, a_{t+h}^*) = \begin{cases} \sigma_a^2 \sum_{j=-n+h}^n c_j c_{j-h}, & h = 0, 1, \dots, 2n \\ 0, & h = 2n+1, \dots \end{cases}$$

- ▶ Ex4 cap2 Morettin e Toloi

Médias Móveis

- ▶ Inferências são limitadas pois o método não é baseado em modelo estatístico.
- ▶ Não podemos obter previsões para $t=T+1, \dots$

- ▶ É bastante usado para análise descritiva.
- ▶ Podemos utilizar medianas móveis.

Médias Móveis

```
ma5 = filter(cmort, sides=2, method="convolution",
rep(1,5)/5)
ma53 = filter(cmort, sides=2,
method="convolution", rep(1,53)/53)
plot(cmort, xlab="week", ylab="mortality", type="l")
lines(ts(ma5, freq=52, start=c(1970,1)), col=2)
lines(ts(ma53,freq=52, start=c(1970,1)), col=4,
lwd=2)
```

Kernel Smoothing

- ▶ Média ponderada

$$\begin{aligned}\hat{f}_t &= \sum_{i=1}^n w_t(i) x_i \\ w_t(i) &= \frac{k(\frac{t-i}{b})}{\sum_{j=1}^n k(\frac{t-j}{b})}\end{aligned}$$

- ▶ O estimador \hat{f}_t é chamado estimador Naradaya–Watson (Watson, 1966).
- ▶ Por exemplo, o kernel normal é $k(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$
- ▶ Quanto maior b , mais suave é \hat{f}_t .

Kernel Smoothing

```
plot(cmort, type="p", ylab="mortality")
lines(ksmooth(time(cmort), cmort, "normal",
bandwidth=5/52))
lines(ksmooth(time(cmort), cmort, "normal",
bandwidth=2))
```

Regressão vizinho mais próximo

- ▶ Regressão com o método vizinho mais próximo é simplesmente uma regressão linear aplicada aos k vizinhos mais próximos $\{xt-k/2, \dots, xt, \dots, xt+k/2\}$ para predizer xt .
- ▶ Locally weighted regression scatter plot smoothing (Lowess) é um método mais complexo que usa uma certa proporção de vizinhos em uma regressão ponderada robusta (após regressão ponderada usa os resíduos para reponderar).
- ▶ Detalhes: Morettin e Tolói (2004) p. 57, Cleveland (1979)

Regressão vizinho mais próximo

- ▶ `par(mfrow=c(2,1))`
- ▶ `plot(cmort, type="p", ylab="mortality", main="nearest neighbor")`
- ▶ `lines(supsmu(time(cmort), cmort, span=.5))`
- ▶ `lines(supsmu(time(cmort), cmort, span=.01))`
- ▶ `plot(cmort, type="p", ylab="mortality", main="lowess")`
- ▶ `lines(lowess(cmort, f=.02))`
- ▶ `lines(lowess(cmort, f=2/3))`

Splines

- ▶ Primeiro os tempos $t = 1, \dots, n$, são separados em k intervalos $[t_0 = 1, t_1], [t_1 + 1, t_2], \dots, [t_{k-1} + 1, t_k = n]$.
- ▶ Os tempos t_1, \dots, t_k são denominados nós. Em cada intervalo é ajustado o modelo de regressão
- ▶ $f_t = T_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \beta_3 t^3$ (em geral de grau 3 = splines cúbicos).
- ▶ A suavização usando splines é obtida minimizando

$$\sum_{t=1}^n (z_t - f_t)^2 + \lambda \int (f_t'')^2 dt.$$

- ▶ A primeira parcela se refere ao ajuste do polinômio e a segunda ao grau de suavidade controlado por λ .

Splines

- ▶

```
plot(cmort, type="p", ylab="mortality")
lines(smooth.spline(time(cmort), cmort))
lines(smooth.spline(time(cmort), cmort,
spar=1))
```
- ▶

Efeitos não lineares

- ▶ Relação entre temperatura e mortalidade
- ▶

```
par(mfrow=c(2,1), mar=c(3,2,1,0)+.5,
    mgp=c(1.6,.6,0))
```
- ▶


```
plot.tempr, cmort, main="lowess",
    xlab="Temperature", ylab="Mortality")
```
- ▶

```
lines(lowess.tempr,cmort))
```
- ▶

```
plot.tempr, cmort, main="smoothing
    splines", xlab="Temperature",
    ylab="Mortality")
```
- ▶

```
lines(smooth.spline.tempr, cmort))
```

Temperatura e mortalidade



Sazonalidade

- ▶ $Z_t = T_t + S_t + a_t$, $t = 1, \dots, T$.
- ▶ Para o modelo aditivo acima, podemos:
 - a. obter estimativas \hat{S}_t de S_t ;
 - b. calcular série dessazonalizada $Z_t^{SA} = Z_t - \hat{S}_t$.

Para modelo multiplicativo, podemos ter $Z_t = T_t S_t + a_t$ e $Y_t = \frac{Z_t}{S_t}$.

- ▶ Sazonalidade determinística

Por exemplo, para dados mensais:

$$Z_t = \beta_0 + \sum_{j=1}^m \beta_j t^j + \sum_{j=1}^{11} \alpha_j D_{jt} + a_t,$$

com D_{jt} variável indicadora que vale 1 se o mês t é igual a j .

Tendência e Sazonalidade

- ▶ Primeiro retira-se a tendência e depois a sazonalidade:

$$\begin{aligned} Y_t &= Z_t - \hat{T}_t \\ \hat{T}_t &= \sum_{j=-n}^n c_j Z_{t+j}. \end{aligned}$$

Para dados mensais (pode estender), temos que para a observação do ano i no mês j , Y_{ij} , temos:

$\bar{Y}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} Y_{ij}$ é a média do mês j .

$\hat{S}_j = \bar{Y}_j - \bar{Y}$ são estimativas das constantes sazonais para

$\bar{Y} = \frac{1}{12} \sum_{j=1}^{12} Y_{.j}$.

Calcula-se $Z_t^{SA} = Z_t - \hat{S}_t$.

Suavização Exponencial Simples

- ▶ Pode ser escrita como

$$\bar{Z}_t = \alpha Z_t + (1 - \alpha) \bar{Z}_{t-1}, \bar{Z}_0 = Z_1, t = 1, \dots, n.$$

- ▶ ou

$$\bar{Z}_t = \alpha \sum_{k=0}^{t-1} (1 - \alpha)^k Z_{t-k} + (1 - \alpha)^t \bar{Z}_0, \bar{Z}_0 = Z_1, t = 1, \dots, n.$$

- ▶ onde \bar{Z}_t é o valor suavizado e $0 \leq \alpha \leq 1$
- ▶ Os pesos são menores para observações mais antigas.

Suavização Exponencial Simples

▶ Previsão

$$\hat{Z}_t(h) = \bar{Z}_t, h = 1, 2, \dots;$$

A atualização da previsão é $\hat{Z}_t(h) = \alpha Z_t + (1 - \alpha)\hat{Z}_{t-1}(h+1)$, sendo $\hat{Z}_{t-1}(h+1)$ a previsão para o tempo t quando temos os dados até $t-1$.

$$E(\hat{Z}_t(h)) = \alpha \sum_{k=0}^{t-1} (1 - \alpha)^k \mu_{t-k}.$$


A expressão do $EQM(\hat{Z}_t(h))$ encontra-se em MT(2006).

Assumindo estacionariedade $Z_t = \mu + a_t$, obtém-se expressões mais simples: $E(\hat{Z}_t(h)) = \mu$ e $Var(\hat{Z}_t(h)) = \frac{\alpha\sigma^2[1-(1-\alpha)^{2t}]}{2-\alpha} \rightarrow \frac{\alpha\sigma^2}{2-\alpha}$ e para $t \rightarrow \infty$.


Suavização Exponencial Simples

- ▶ Esse método é conhecido como EWMA (Exponential Weighting Moving Averages);
- ▶ O método é ótimo se Z_t for ARIMA(0,1,1).
- ▶ Há vários métodos de escolha de α .
- ▶ Esse método é muito utilizado para estimar a volatilidade usando-se os log-retornos ao quadrado.


Ibovespa



Log retorno




SES de logret² para variâncias



Suavização Exponencial Simples – Ibovespa

- ▶ library(forecast)
- ▶ ? Ses
- ▶ Dados desde 2010



Suavização de Holt

- ▶ Para $Z_t = \mu + T_t + a_t$
- ▶ Os valores de nível e tendência são estimados por

$$\bar{Z}_t = AZ_t + (1 - A)(\bar{Z}_{t-1} + \hat{T}_{t-1}), \quad 0 < A < 1;$$

$$\hat{T}_t = C(\bar{Z}_t - \bar{Z}_{t-1}) + (1 - C)\hat{T}_{t-1}, \quad 0 < C < 1.$$

- ▶ Observações

Previsão: $\hat{Z}_t(h) = \bar{Z}_t + h\hat{T}_t, h > 0.$

A e C são estimados por exemplo de modo a minimizar $\sum a_t^2$.

Fornece previsões ótimas se Z_t for gerado a partir de processo ARIMA(0,2,2).

- ▶ `fcast <- holt(airmiles)`
- ▶ `plot(fcast)`

Holt-Winters

- ▶ A série com período s , fator sazonal multiplicativo (F_t) e tendência aditiva é
- ▶ $Z_t = \mu_t F_t + T_t + a_t, t = 1, \dots, T.$
- ▶ Equações de suavização para $t = s+1, \dots, T$:
$$\hat{F}_t = D \frac{Z_t}{\bar{Z}_t} + (1 - D) \hat{F}_{t-s}, 0 < D < 1.$$
$$\bar{Z}_t = A \frac{Z_t}{\hat{F}_{t-s}} + (1 - A)(\bar{Z}_{t-1} - \hat{T}_{t-1}), 0 < A < 1;$$
$$\hat{T}_t = C(\bar{Z}_t - \bar{Z}_{t-1}) + (1 - C)\hat{T}_{t-1}, 0 < C < 1.$$
- ▶ A, C e D estimados por mínimos quadrados.

Holt- Winters – Hyndman


- ▶ <https://www.otexts.org/fpp/7/2>
- ▶ library(fpp)
- ▶

```
air <- window(ausair,start=1990,end=2004)
fit1 <- holt(air, alpha=0.8, beta=0.2, initial="simple", h=5)
fit2 <- holt(air, alpha=0.8, beta=0.2, initial="simple", exponential=TRUE, h=5)
# Results for first model:
fit1$model$state
fitted(fit1)
fit1$mean
```
- ▶

```
fit3 <- holt(air, alpha=0.8, beta=0.2, damped=TRUE, initial="simple", h=5)
plot(fit2, type="o", ylab="Air passengers in Australia (millions)", xlab="Year",
     fcol="white", plot.conf=FALSE)
lines(fitted(fit1), col="blue")
lines(fitted(fit2), col="red")
lines(fitted(fit3), col="green")
lines(fit1$mean, col="blue", type="o")
lines(fit2$mean, col="red", type="o")
lines(fit3$mean, col="green", type="o")
legend("topleft", lty=1, col=c("black","blue","red","green"),
       c("Data","Holt's linear trend","Exponential trend","Additive damped trend"))
```


Vários métodos

Forecasts from Holt's method with exponential trend



Decomposição Tendência Sazonalidade usando lowess – STL

- ▶ Cleveland



- ▶ `plot(stl(log(co2), s.window="per", t.window=1000))`
- ▶ Ler artigo Cleveland et al. (1990)

Referências

- ▶ Shumway and Stoffer (2006)
- ▶ Morettin e Toloi (2006)
- ▶ Hyndman and Athanasopoulos (2012). *Forecasting: principles and practice*
- ▶ <https://www.otexts.org/fpp>
- ▶ R. B. Cleveland, W. S. Cleveland, J.E. McRae, and I. Terpenning (1990) STL: A Seasonal–Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*, 6, 3–73.
- ▶ www.r-project.org