


Tendência e Sazonalidade


Lane Alencar
www.ime.usp.br/~lane

Número de passageiros de voos internacionais




?AirPassengers
ts.plot(AirPassengers)

Produção Industrial – IBGE



- ▶ Fonte: IPEA
- ▶ www.ipeadata.gov.br
- ▶ Media de 2002=100

Mortalidade, Temperatura, Poluição



Fonte: Shumway e Stoffer (2006)

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 $\text{Var}(a_t) = \sigma^2$.

Métodos descritivos e de suavização

- ▶ Modelo Polinomial:
- ▶ Médias Móveis: Suavizar os valores da série para estimar a tendência em cada instante;
- ▶ Lowess: Suavizar a série com ajustes sucessivos de retas de mínimos quadrados (lowess);

Polinômio

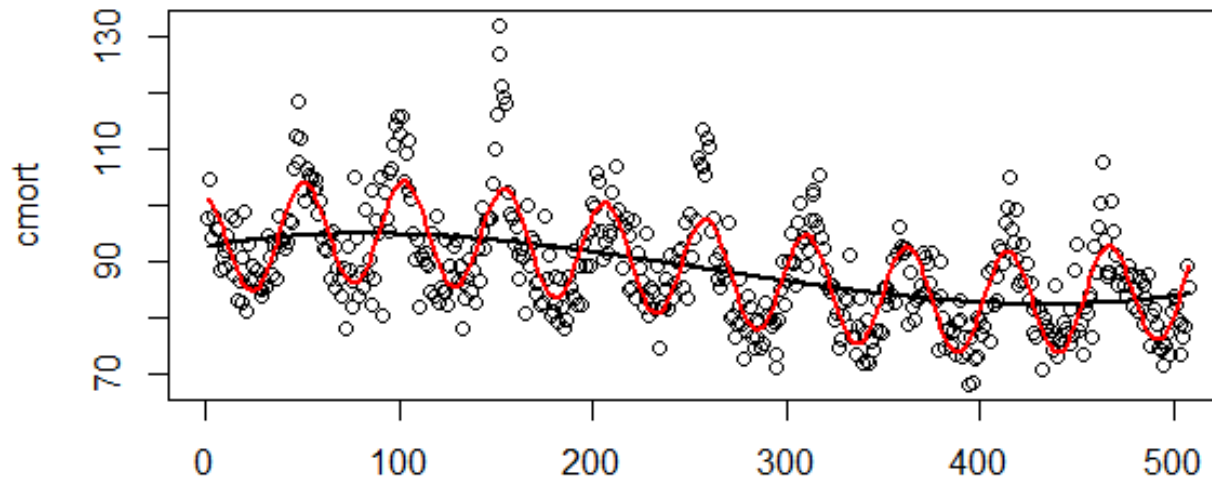
- ▶ Supomos $T_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \dots + \beta_p t^p$.
Ajustando o polinômio pelo método de mínimos quadrados temos que minimizar

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

Polinômio


- ▶ # Mortalidade cardiovascular semanal de 1970 a 1979
- ▶ # Dados e programas em Shumway e Stoffer (2006)
- ▶ library(astsa)
- ▶ cmort=cmort\$V1
- ▶ t = 1:length(cmort)
- ▶ t2 = t^2
- ▶ t3 = t^3
- ▶ c = cos(2*pi*t/52)
- ▶ s = sin(2*pi*t/52)
- ▶ fit1 = lm(mort ~ t + t2 + t3)
- ▶ fit2 = lm(mort ~ t + t2 + t3 + c + s)
- ▶ plot(t, mort)
- ▶ lines(fit1\$fit)
- ▶ lines(fit2\$fit)

Mortalidade Cardiovascular



- ▶ Average weekly cardiovascular mortality in Los Angeles County; 508 six-day smoothed averages obtained by filtering daily values over the 10 year period 1970–1979.

Mortalidade Cardiovascular



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

- ▶ 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 conseqüentemente $Var(Z_t^*) < Var(Z_t)$.

Médias Móveis

- ▶ Introduzimos correlação nos erros.
- ▶ Supondo $\text{Cov}(a_t, a_s) = 0, s \neq t$, obtemos:
$$\text{Cov}(a_t^*, a_s^*) = \sigma^2 \sum_{j=-n+h}^n c_j c_{j-h}, h = 0, 1, \dots, 2n$$
- ▶ e zero caso contrário.


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

- ▶ `mort <- read.table("http://www.stat.pitt.edu/stoffer/tsa2/data/cmort.dat", header=FALSE, sep="," , na.strings="NA", dec=".", strip.white=TRUE)`
- ▶ `mort=mort$V1`
- ▶ `t = 1:length(mort)`
- ▶ `ma5 = filter(mort, sides=2, rep(1,5)/5)`
- ▶ `ma53 = filter(mort, sides=2, rep(1,53)/53)`
- ▶ `plot(t, mort, xlab="week", ylab="mortality")`
- ▶ `lines(ma5)`
- ▶ `lines(ma53)`

Médias móveis – Mortalidade



Kernel Smoothing


- ▶ Média ponderada

$$\hat{f}_t = \sum_{i=1}^n w_t(i) x_i$$
$$w_t(i) = \frac{k\left(\frac{t-i}{b}\right)}{\sum_{j=1}^n k\left(\frac{t-j}{b}\right)}$$

- ▶ 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(t, mort)`
- ▶ `lines(ksmooth(t, mort, "normal", bandwidth=5))`
- ▶ `lines(ksmooth(t, mort, "normal", bandwidth=104))`



Regressão vizinho mais próximo


- ▶ Regressão com o método vizinho mais próximo é simplesmente uma regressão linear aplicada aos k vizinhos mais próximos $\{x_{t-k/2}, \dots, x_t, \dots, x_{t+k/2}\}$ para prever x_t .
- ▶ 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).
- ▶ Leia Cleveland (1979)

Regressão vizinho mais próximo


- ▶ #mortalidade cardiovascular semanal
- ▶ $n=508$
- ▶ $k=n/2$ #tendência,
- ▶ $k=n/100$ #componente sazonal
- ▶ `par(mfrow=c(2,1))`
- ▶ `plot(t, mort, main="nearest neighbor")`
- ▶ `lines(supsmu(t, mort, span=.5))`
- ▶ `lines(supsmu(t, mort, span=.01))`
- ▶ `plot(t, mort, main="lowess")`
- ▶ `lines(lowess(t, mort, .02))`
- ▶ `lines(lowess(t, mort, 2/3))`

Vizinho mais próximo e Lowess

nearest neighbor



lowess



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(t, cmort)`
- ▶ `lines(smooth.spline(t, cmort, spar=1))`
- ▶ `lines(smooth.spline(t, cmort, spar=.1), col=2)`


- ▶ `par(mfrow=c(2,1))`
- ▶ `plot(t, cmort, main="lowess")`
- ▶ `lines(lowess(t,cmort))`
- ▶ `plot(t, cmort, main="smoothing splines")`
- ▶ `lines(smooth.spline(t,cmort))`

Suavização

lowess



smoothing splines



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 $Y_t = \frac{Z_t}{\hat{S}_t}$.

▶ 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:

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

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

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

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 $Z_t = \mu + a_t$, obtem-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 - Fechamento diário



Fonte: Yahoo Finance

Ibovespa - Log retornos




Log retorno = $\ln(P_t) - \ln(P_{t-1})$, sendo P_t o preço de fechamento


Suavização Exponencial Simples – Ibovespa

- ▶ `library(forecast)`
- ▶ `? ses`
- ▶ `d <- read.table("/dados/Inretibov.csv", header=TRUE, sep=";", na.strings="NA", dec=".", strip.white=TRUE)`
- ▶ `ts.plot(d$Inretibov)`
- ▶ `f=ses(d$Inretibov^2)`
- ▶ `ts.plot(d$Inretibov)`
- ▶ `lines(2*sqrt(f$fitted),col=2)`
- ▶ `lines(-2*sqrt(f$fitted),col=2)`

Suavização exponencial simples do log retorno



Intervalo para log retorno



SES de $\log \text{ret}^2$ para estimar variâncias
IC=[0 \pm raiz(variância)]

Suavização de Holt

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

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

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

- ▶ 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)`

Suavização Holt

Forecasts from Holt's method



Passenger-miles flown by U.S. commercial airlines


- ▶ `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


Forecasts from Holt-Winters' additive method



- ▶ `deaths.fcast <- hw(USAccDeaths,h=48)`
- ▶ `plot(deaths.fcast)`

Decomposição Tendência Sazonalidade usando lowess

- ▶ Cleveland(1990) – STL



Mortalidade Cardiovascular – Shumway e Stoffer

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

Referências

- ▶ Shumway and Stoffer (2006)
- ▶ Morettin e Toloí (2006)
- ▶ Cleveland, W. S. (1979) Robust locally weighted regression and smoothing scatterplots. *J. American Statistical Association* **74**, 829–836.
- ▶ Cleveland, W. S. (1981) LOWESS: A program for smoothing scatterplots by robust locally weighted regression. *The American Statistician* **35**, 54
- ▶ 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