


# Serie Storiche

Laboratorio di Data Science  
in Economia

CLEBA



Roberto Benedetti

Dipartimento di Economia, email  
[benedett@unich.it](mailto:benedett@unich.it)


# Argomenti trattati

- Concetti basilari
- I modelli ARMA
- La nonstazionarietà
- La previsione
- Applicazioni

# SERIE STORICHE CON R

- ALCUNE OPERAZIONI PREVISTE NELLE STATISTICHE DI BASE DI R
- Installare PACKAGE : `tseries`

Springer Texts in Statistics



© 2008

## Time Series Analysis

With Applications in R

Authors: **Cryer**, Jonathan D., **Chan**, Kung-Sik

# SERIE STORICHE CON R


Book  
Springer Texts in Statistics  
2011

## Time Series Analysis and Its Applications

With R Examples

**Authors:** Robert H. Shumway, David S. Stoffer

ISBN: 978-1-4419-7864-6 (Print) 978-1-4419-7865-3 (Online)



DISPENSA di VITO RICCI:

<https://cran.r-project.org/doc/contrib/Ricci-ts-italian.pdf>

# Definizione di serie storica

Definizione operativa non formale:

Una serie storica è una sequenza ordinata di osservazioni, dove l'ordine è dato dal tempo

I valori possono essere **quantitativi** o **qualitativi**


La serie storica può essere di natura **discreta** (nel tempo non nei valori) o **continua**, e può essere osservata ad intervalli regolari o no.

Noi analizziamo solo serie storiche **discrete** osservate ad intervalli regolari di valori **quantitativi**


# L'analisi delle serie storiche per...

1. Descrivere un fenomeno osservato
2. Prevedere valori futuri
3. Studiare impatto di shock
4. Analizzare dinamiche congiunturali
5. Destagionalizzare


# Esempio di serie storica: Google Trend Mensile




# Esempio di serie storica: Google Trend Settimanale




# Esempio di serie storica: World Population, GDP and Per Capita GDP, 1-2003 AD (Angus Maddison)




# Esempio di serie storica: La ricostruzione Banca d'Italia-Istat 1861-2015 (da Statistiche storiche della Banca d'Italia)




# Esempio di serie storica: Prezzi medi al consumo di alcuni prodotti del comparto alimentare - Anni 1861-2015 (euro 2015)




# Esempio di serie storica: classici dati di Box & Jenkins su airolinee. Totali mensili dei passeggeri internazionali dal 1949 al 1960



# Esempio di serie storica: quotazioni Apple Computer



# Esempio di serie storiche: prezzi mensili di petrolio e benzina



## Esempi di serie storica: R Script

```
setwd("~/Documents/prova r pkg/lucidi del corso")
datigtm <- read.csv(file="RMatlab.csv")
datigtw <- read.csv(file="RMatlab week.csv")
tsgtm <- ts(datigtm[,2:3], frequency = 12, start = c(2004, 1)) # frequency 12 => Monthly Data
par(mar=c(4.5,4.5,1,1))
plot(tsgtm,cex.lab=2,main="",plot.type = "single",lty=1,lwd=c(2,1),ylab="")
legend(2012,90, c("R","Matlab"), lwd=c(2,1),cex=1.5)
library(lubridate)
tsgtw <- ts(datigtw[,2:3], freq=365.25/7, start=decimal_date(ymd("2014-06-29")))
par(mar=c(4.5,4.5,1,1))
plot(tsgtw,cex.lab=2,main="",plot.type = "single",lty=1,lwd=c(2,1),ylab="")
legend(2015,50, c("R","Matlab"), lwd=c(2,1),cex=1.5)
gdppc <- read.table(file="percapitagdp.csv",sep=";",dec=".",header = T)
tsgdp <- ts(gdppc[6:189,2:183], frequency = 1, start = c(1820))

plot(tsgdp[,c(5,7)],cex.lab=2,main="",plot.type = "single",lty=c(1,1),lwd=c(2,1),ylab="")
legend(1850,15000, c("Francia","Italia"), lty=c(1,1),lwd=c(2,1),cex=1.5)
```

## Esempi di serie storica: R Script

```
gdppc_it_bi <- read.table(file="gdppc_it_bi.csv",sep=";",dec="," ,header = T)
tsgdp_it_bi <- ts(gdppc_it_bi[,2:4], frequency = 1, start = c(1861))
plot(tsgdp_it_bi[,3],main="",lwd=2,ylab="")
```

```
data("AirPassengers")
AP <- AirPassengers
plot(AP, ylab="Passengers (1000s)", type="o", pch =19, cex=0.7)
```

```
prezzi <- read.table(file="prezzi.csv",sep=";",dec="," ,header = T)
prezzi_istat <- ts(prezzi[,2:17], frequency = 1, start = c(1861))
par(mar=c(4.5,1,1,1))
plot(prezzi_istat[,c(1,5,16)],cex.lab=2,main="",plot.type =
"single",lty=c(1,2,2),lwd=c(2,2,1),ylab="")
legend(1865,15, c("Pane", "Carne Bov", "Zucchero"), lty=c(1,2,2),lwd=c(2,2,1),cex=1)
```

```
apple <- read.csv(file="AAPL.csv",header = T)
apple$Date <- as.Date(apple$Date)
tsapple <- ts(apple[,2:7], start = c(1980, as.numeric(format(inds[1], "%j"))),frequency = 365)
par(mar=c(4.5,4.5,1,1))
plot(tsapple[,5], main="",lwd=1,ylab="Quotazioni Apple")
```

# Approcci di analisi

## APPROCCIO DETERMINISTICO

- scomporre la serie nelle sue componenti

## APPROCCIO STOCASTICO

- trovare processo generatore dei dati

# Decomposizione di una serie storica

Ogni dato ( $Y_t$ ) al tempo  $t$  di una serie storica può essere espresso come somma o prodotto di 3 componenti, ovvero Seasonality ( $S_t$ ), Trend ( $T_t$ ) ed Errore ( $\varepsilon_t$ ) (detto White Noise).

Per le serie storiche additive,


$$Y_t = S_t + T_t + \varepsilon_t$$

Per le serie storiche moltiplicative,

$$Y_t = S_t \times T_t \times \varepsilon_t$$


Una serie storica moltiplicativa può essere convertita in additiva calcolandone il logaritmo

# Componenti di una serie storica



# Componente trend

- ◆ Schema persistente, complessivamente verso l'alto o verso il basso
- ◆ Cambiamenti dovuti a popolazione, tecnologia, età, cultura, ecc.
- ◆ In genere per diverse occasioni




# Componente stagionale

- ◆ Schema regolare delle fluttuazioni su e giù
- ◆ A causa del tempo, delle abitudini, ecc.
- ◆ Si verifica entro un periodo ben definito

<b>Period</b>	<b>Length</b>	<b>Number of Seasons</b>
<b>Week</b>	<b>Day</b>	<b>7</b>
<b>Month</b>	<b>Week</b>	<b>4-4.5</b>
<b>Month</b>	<b>Day</b>	<b>28-31</b>
<b>Year</b>	<b>Quarter</b>	<b>4</b>
<b>Year</b>	<b>Month</b>	<b>12</b>
<b>Year</b>	<b>Week</b>	<b>52</b>


# Componente ciclica

- ◆ Si ripetono i movimenti su e giù
- ◆ Interessato da ciclo economico, fattori politici ed economici
- ◆ Durata di medio lungo periodo (ad esempio più anni)



# Componente casuale


- ◆ Fluttuazioni "residue" irregolari, non sistematiche
- ◆ A causa di variazioni casuali o eventi imprevedibili
- ◆ Breve durata e non ripetizione



# Decomposizione di una serie storica

La funzione `decompose()` divide le serie storiche in componenti stagionali, trend ed errori.


```
decAP <- decompose(AP, type =  
"multiplicative")
```



# Decomposizione di una serie storica

La funzione `decompose()` divide le serie storiche in componenti stagionali, trend ed errori.


```
decAP <- decompose(AP, type =  
"additive")
```



# Decemposizione di una serie storica


```
decMatlab <- decompose(tsgtm[,2], type =  
  "multiplicative")  
plot(decMatlab)
```

Decomposition of multiplicative time series



# Approccio Stocastico

Realizations of a stochastic process



# Approccio Stocastico

- al variare di  $t$  e di  $\omega$   $X(t,\omega)$  è un **PROCESSO STOCASTICO**
- al variare di  $t$ ,  $X(t,\omega)$  è una **VARIABILE CASUALE**
- al variare di  $\omega$ ,  $X(t,\omega)$  è una **REALIZZAZIONE**
- fissati  $t$  e  $\omega$ ,  $X(t,\omega)$  è un **VALORE REALE**

# Approccio Stocastico

- Approccio stocastico
- Obiettivo determinare la legge che "governa" il processo
- Il passato spiega il presente e il futuro
- Modelli lineari che spiegano guardando il passato

# Approccio Stocastico

L'obiettivo principale dell'analisi delle serie storiche è quello di sviluppare modelli matematici che riescano a descrivere in modo plausibile il campione osservato.

Punti adiacenti nel tempo sono correlati tra loro, pertanto il valore della serie osservato al tempo  $t$  dipenderà in qualche maniera dai valori passati

$$X_{t-1}, X_{t-2}, \dots$$

Tale considerazione è alla base della costruzione e analisi delle serie storiche.

# Modelli Lineari Univariati

- STIAMO LIMITANDO L'ATTENZIONE A MODELLI **LINEARI**
- STIAMO OSSERVANDO SOLO **UNA** VARIABILE X NEL TEMPO
- SPIEGHIAMO IL VALORE ATTUALE  $X_t$  OSSERVANDO IL PASSATO
  - ➔ DEFINIZIONE DI VARIABILE RITARDATA

# Variabile Ritardata

$X_t$	$X_{t-1}$	$X_{t-2}$	$X_{t-3}$
$X_1$	--	--	--
$X_2$	$X_1$	--	--
$X_3$	$X_2$	$X_1$	--
$X_4$	$X_3$	$X_2$	$X_1$
$X_5$	$X_4$	$X_3$	$X_2$

# Variabile Ritardata

$X_t$	$X_{t-1}$	$X_{t-2}$	$X_{t-3}$
3,2	--	--	--
2,8	3,2	--	--
5,4	2,8	3,2	--
7,2	5,4	2,8	3,2
6,3	7,2	5,4	2,8

# Operatore Ritardo

L'operatore ritardo è indicato con "L" (*Lag*) ed è definito come segue:

$$L^1 X_t = X_{t-1}$$

$$L^2 X_t = X_{t-2}$$

$$L^3 X_t = X_{t-3}$$

A volte viene indicato con B (= Backshift)

# Trasformazioni

Molto spesso nella elaborazione dei dati statistici le variabili vengono trasformate. Basti pensare all'analisi del PIL, il quale viene sempre analizzato, non nel valore, assoluto, ma in termini di variazione percentuale.

Le trasformazioni utili a fini interpretativi dei fenomeni sono:

- variazione assoluta
- variazione percentuale

# Trasformazioni

## Le trasformazioni

La variazione assoluta si ottiene immediatamente come differenza del valore di  $X$  al tempo  $t$  rispetto allo stesso un tempo precedente:

$$\Delta X_t = X_t - X_{t-1}$$

Il simbolo usato per la differenza assoluta è  $\Delta$ .  
Analizzando  $\Delta X$  piuttosto che  $X$ , il modello specificato spiegherà la variazione di  $X$ .

# Trasformazioni

## Le trasformazioni

Il ritardo di una variabile può essere definito anche introducendo l'**OPERATORE RITARDO**:

$$LX_t = X_{t-1}$$

$$L^2X_t = X_{t-2}$$

...

$$L^pX_t = X_{t-p}$$

Avremo allora che

$$\Delta X_t = X_t - X_{t-1} = X_t - LX_t = (1 - L)X_t$$

# Trasformazioni

## Le trasformazioni

L'altra trasformazione importante è quella che porta al tasso di variazione della serie  $\frac{X_t - X_{t-1}}{X_{t-1}}$

Si dimostra facilmente che questa è ben approssimata dalla seguente espressione

$$\frac{X_t - X_{t-1}}{X_{t-1}} \approx \log X_t - \log X_{t-1} = \Delta \log X_t$$

Molto spesso quindi piuttosto che rilevare  $Y_t$ , si studierà  $\log Y_t$  e poi, successivamente, la sua variazione.

La trasformazione logaritmica viene ampiamente utilizzata in statistica.

# Trasformazioni

## Le trasformazioni




Fig. 3 – Trasformazione logaritmiche (B) di una serie storica (A).

# Modello regressione

Modello di regressione:

- ✓ assunzione di **independenza** delle osservazioni
- ✓ La variabile dipendente  $Y$  è funzione di variabili esplicative  $X_1, \dots, X_k$
- ✓ Si usa il coefficiente di correlazione  $r$

$$Y_t = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k + \varepsilon_t$$

# Modello serie storiche

- Modelli Serie storiche:
  - ✓ Dipendenza tra osservazioni
  - ✓ X spiegata dal suo passato
  - ✓ Uso dell'autocorrelazione

$$X_t = \alpha + \phi_1 X_{t-1} + \dots + \phi_k X_{t-k} + \varepsilon_t$$

# Statistiche di base

## MODELLO REGRESSIONE

- media
- varianza
- correlazione

## MODELLO SERIE STORICHE

- media
- varianza
- autocorrelazione

# Correlazione

La correlazione misura il legame lineare tra  $X_t$  e  $Y_t$

Se  $\rho = 0$ : nessuna relazione lineare

Se  $\rho = +1$ : relazione lineare perfetta crescente

Se  $\rho = -1$ : relazione lineare perfetta decrescente

$$-1 \leq \rho_{X,Y} \leq +1$$


# Autocorrelazione

Autocorrelazione (ACF) misura la dipendenza lineare tra  $X_t$  and  $X_{t-k}$

$$\rho(k) = \text{corr}(X_{t-1}, X_{t-k})$$

# Autocorrelogramma

- Il grafico dell'autocorrelazione al variare del ritardo  $k$  è detto **correlogramma**




# Stazionarietà

Necessario porre delle restrizioni su alcune proprietà fondamentali:  
stazionarietà debole



$$\begin{aligned}E(X_t) &= \mu = \text{const}, & \forall t \\E(X_t - \mu)^2 &= \sigma^2 = \text{const} < +\infty, \\E[(X_t - \mu)(X_{t-k} - \mu)] &= \gamma_k\end{aligned}$$

La media e la varianza sono costanti, l'autocorrelazione dipende solo da  $k$  e non da  $t$ .

# Serie stazionarie



# Serie non stazionarie



# Modelli stazionari

Esistono diversi modelli per descrivere un processo stazionario:

- Moving average MA (*Media mobile*)
- Autoregressive Model AR  
(*Autoregressivo*)
- Mixed Autoregressive Moving Average model  
ARMA

E poi esistono diversi modelli per descrivere processi non stazionari.

# Modelli lineari

**MA(q):**

$$X_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

**AR(p):**

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t$$

# Modelli lineari

## ARMA(p,q):

**Dove  $X$  è il fenomeno sotto osservazione e  $a$  sono gli shock (imprevedibili) che si verificano**

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + a_t - \theta_1 a_{t-1} + \dots - \theta_q a_{t-q}$$

# Modelli lineari

## White Noise (WN):


Dove  $a_t$  è uno shock casuale gaussiano, ossia:

$$X_t = a_t$$

$$a_t \approx N(0, \sigma)$$

$$\rho(k) = 0 = \lambda(k) \quad \forall k$$

# BOX-JENKINS



# Identificazione

Necessario capire dai dati, quale è il modello più appropriato a descrive la nostra serie osservata (AR, MA, ARMA?)

Capire l'ordine del modello ( $p, q$ ?)

Tale fase si basa sullo studio di alcune statistiche campionarie:

ACF ( $= \rho_k$ ), PACF ( $= \lambda_k$ )

# Identificazione

Ogni modello presenta un andamento teorico di ACF e PACF ben preciso.

Sulla base della corrispondenza tra ACF e PACF campionaria e teorica è possibile abbinare l'appropriato modello ai dati osservati.

Solo dopo attenta lettura e interpretazione di ACF e PACF si passa alla stima del modello.

# Identificazione AR(1)

Modello AR(1):

$$X_t = \phi_1 X_{t-1} + a_t$$

Mi aspetto che ci sia autocorrelazione solo per  $k = 1$

Invece NO!!


$X_{t-1}$  sarà influenzata da  $X_{t-2}$  e quindi ci sarà una relazione indiretta anche tra  $X_t$  e  $X_{t-2}$ , etc.

# Identificazione AR(1)

Correlogramma ACF di un processo AR(1):

Introduciamo la Partial AutoCorrelation Function (PACF):

= La correlazione tra  $X_t$  e  $X_{t-k}$ , tolti tutti i legami intermedi indotti




# Identificazione AR(1) - simulazione

```
set.seed(12345)
par(mfrow=c(3,1),mar=c(4.5,4.5,1,1))
sersim <- arima.sim(n = 300, list(ar = c(0.9,
+      0), ma = c(0, 0)), sd = sqrt(2))
plot(sersim)
acfsim <- acf(sersim,20,type="correlation")
pacfsim <- pacf(sersim,20)
```

# Identificazione AR(1)







ACF e PACF di un AR(1) con  $\phi_1 < 0$ , in questo caso pari a -0.9



# Identificazione AR(2)

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + a_t$$

$$\varphi_1 > 0, \quad \varphi_2 > 0$$









$$\varphi_1 < 0, \quad \varphi_2 < 0$$

# Identificazione AR(2)

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + a_t$$

$$\varphi_1 > 0, \quad \varphi_2 < 0$$



$$\varphi_1 < 0, \quad \varphi_2 > 0$$

# Identificazione AR(p)

ACF: decresce lentamente all'aumentare di  $k$

PACF: è nulla per  $k > p$



Riportare sul grafico ACF e PACF le linee di significatività, per serie osservate  $X_t$

# Identificazione AR(p)

Per verificare se ACF e PACF sono significativamente diversi da zero, si usa la regola empirica:

$$|\hat{\rho}| > 2 \sqrt{\frac{1}{n}}$$

Esempio: ACF e PACF con livelli di significatività




# Identificazione MA(1)


Modello MA(1):

$$X_t = a_t - \theta_1 a_{t-1}$$

ACF




PACF









# Identificazione MA(1)

$$Z_t = \varepsilon_t + 0.9\varepsilon_{t-1}$$



# Identificazione MA(1)

$$\theta_1 > 0, \theta_2 > 0$$



$$\theta_1 < 0, \theta_2 < 0$$

# Identificazione MA(q)

ACF: è nulla per  $k > q$

PACF: decresce lentamente all'aumentare di  $k$

Riportare sul grafico ACF e PACF le linee di significatività, per serie osservate  $X_t$

# Modelli ARMA(p,q)

$$Z_t = \overbrace{\varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p}}^{AR(p)} + a_t \underbrace{-\vartheta_1 a_{t-1} - \vartheta_2 a_{t-2} + \dots - \vartheta_q a_{t-q}}_{MA(q)},$$

Questo è il modello Autoregressivo a Media Mobile **ARMA ( p, q )**. Casi particolari sono:


$$ARMA(p,0) = AR(p) : Z_t = \varphi_1 Z_{t-1} + \dots + \varphi_p Z_{t-p} + a_t$$

$$ARMA(0,q) = MA(q) : Z_t = a_t - \vartheta_1 a_{t-1} + \dots - \vartheta_q a_{t-q}$$


$$ARMA(1,1) : Z_t = \varphi_1 Z_{t-1} + a_t + \vartheta_1 a_{t-1}$$

# Modelli ARMA(1,1)

ACF and PACF of ARMA(1,1) processes



# BOX-JENKINS



# Identificazione ARMA(p,q)

<b>Modello</b>	<b>ACF</b>	<b>PACF</b>
<b>AR (p)</b>	<b>Diminuisce esponenzialmente</b>	<b>nulla per <math>k &gt; p</math></b>
<b>MA (q)</b>	<b>Nulla per <math>k &gt; q</math></b>	<b>Diminuisce esponenzialmente</b>
<b>ARMA (p,q)</b>	<b>Nulla per <math>k &gt; (q-p)</math></b>	<b>Nulla per <math>k &gt; (p-q)</math></b>

# Passaggi per identificazione modello ARMA(p,q)

*“The art of a time series analyst’s model identification is very much like the method of an FBI agent’s criminal search. Most criminals disguise themselves to avoid being recognized. This is also true of ACF and PACF” (Wei, 1990)*

**Step 1:** Grafico della serie e trasformazioni (log, differenza, differenza percentuale,...)

**Step 2:** Calcolare ACF e PACF campionarie


**Step 3:** Identificare il modello ARMA(p,q) da stimare

# Stima modello ARMA(p,q)

1. AR(p) OLS corretto consistente ed efficiente, quindi MLE
2. MA(q) OLS non è possibile perché i regressori sono incogniti. Si utilizza la stima MLE che richiede un'ipotesi sulla distribuzione dei termini di disturbo e procedure numeriche di massimizzazione (Algoritmo di Newton)
3. ARMA(p,q) vedi punto 2



# Esempio: Lake Huron

- Utilizziamo la serie "Annual levels of the Lake Huron from 1875 to 1972"



# Esempio: Lake Huron

- Calcoliamo ACF e PACF,  $k=20$



# Esempio: Lake Huron

Stimiamo il modello AR(2):

```
arima(LakeHuron, order=c(2,0,0))
```

Coefficients:

```
      ar1      ar2  intercept
1.0436 -0.2495  579.0473
s.e. 0.0983  0.1008   0.3319
```

sigma<sup>2</sup> estimated as 0.4788:

log likelihood = -103.63, aic = 215.27

```
library(lmtest)
```

```
coeftest(stilak)
```

z test of coefficients:

	Estimate	Std. Error	z value	Pr(> z )	
ar1	1.043614	0.098283	10.6185	< 2e-16	***
ar2	-0.249498	0.100792	-2.4754	0.01331	*
intercept	579.047322	0.331876	1744.7727	< 2e-16	***

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

1. I valori dei coefficienti

2. Lo standard error  $\sigma$

3. La t-student (= coefficiente / s.e.)

4. Il p-value

# Diagnostic checking e criteri di selezione

- Dopo aver stimato il modello, dobbiamo verificare la bontà del modello stesso.
- L'assunzione è che il residuo stimato sia un "White noise"
  - No autocorrelazione
  - Distribuzione Normale
- Se abbiamo più modelli possibili → applicare criterio di selezione

# Diagnostic checking: Lake Huron

