

# Serie storiche


# Introduzione

- Per alcuni dataset, l'attributo target è soggetto ad un'evoluzione temporale e risulta associato ad istanti di tempo successivi.
- I modelli di analisi delle serie storiche si propongono di identificare eventuali regolarità, con l'obiettivo di ricavare predizioni per il futuro.
- Vedremo alcuni esempi, i principali indicatori di valutazione, i metodi di scomposizione e quelli predittivi.

# Definizione di serie storica

- Una *serie storica* è una sequenza di valori  $\{y_t\}$  assunti da una grandezza misurabile in corrispondenza di specifici istanti temporali  $t$ .
  - Istanti di tempo  $t$  discreti: *serie a tempo discreto*.
  - Altrimenti, *serie a tempo continuo*.
- Analizzeremo serie a tempo discreto e supporremo gli istanti  $t$  distribuiti uniformemente.

# Consumo elettrico bimestrale



# Modello di serie storica

- Supponiamo che ciascuna osservazione  $y_t$  rappresenti la realizzazione di una variabile casuale  $Y_t$ .
- Un modello della serie storica  $\{y_t\}$  consiste nella definizione della distribuzione di probabilità congiunta della sequenza di variabili casuali  $\{Y_t\}$ .
- I modelli predittivi analizzano le serie per evidenziare le regolarità che si sono verificate nel passato, per effettuare previsioni.
- Detta  $f_t$  una predizione del valore casuale  $Y_t$ , cerchiamo  $F$ :

$$f_{t+1} = F(y_t, y_{t-1}, \dots, y_{t-k+1})$$

idonea a rappresentare la serie storica.

# Valutazione dei modelli

- Nella fase di identificazione e sviluppo di un modello, la misura dell'accuratezza permette di confrontare modelli diversi.
- Dopo averlo sviluppato e utilizzato, occorre svolgere periodicamente il monitoraggio dell'accuratezza, per evidenziare eventuali anomalie o inadeguatezze.

➤ *Errore di predizione:*

$$e_t = y_t - f_t$$

➤ *Errore di predizione percentuale:*

$$e_t^P = \frac{y_t - f_t}{y_t} \times 100$$

# Misure di distorsione

- *Errore medio*

$$ME = \frac{\sum_{t=1}^k e_t}{k} = \frac{\sum_{t=1}^k (y_t - f_t)}{k}$$

- *Errore percentuale medio*

$$MPE = \frac{\sum_{t=1}^k e_t^P}{k}$$

- Tra due modelli si ritiene migliore quello con errore medio più prossimo a zero.

# Misure di dispersione

- *Scarto medio assoluto (MAD)*


$$MAD = \frac{\sum_{t=1}^k |e_t|}{k} = \frac{\sum_{t=1}^k |y_t - f_t|}{k}$$

- *Scarto percentuale medio assoluto (MAPE)*

$$MAPE = \frac{\sum_{t=1}^k |e_t^P|}{k}$$

- *Scarto quadratico medio (MSE)*

$$MSE = \frac{\sum_{t=1}^k |e_t^2|}{k} = \frac{\sum_{t=1}^k (y_t - f_t)^2}{k}$$





# Segnale di tracking

- Indicatore utile in fase di monitoraggio del modello

$$TS_k = \frac{\sum_{t=1}^k e_t}{\sum_{t=1}^k |e_t|}$$

- $TS_k \approx 0 \Rightarrow$  Previsioni in linea con quelle osservate
  - $TS_k \approx -1 \Rightarrow$  Previsioni inferiori a quelle osservate
  - $TS_k \approx 1 \Rightarrow$  Previsioni superiori a quelle osservate
- Il segnale di tracking viene confrontato con una soglia e se la condizione è violata, viene segnalata un'anomalia.

# Analisi delle componenti

$$Y_t = g(M_t, Q_t, \varepsilon_t)$$

- **Tendenza.** Andamento medio della serie nel tempo ( $M_t$ ).
  - Si cerca di approssimare  $M_t$  con funzioni semplici.
- **Stagionalità.** Fluttuazioni di periodicità regolare ( $Q_t$ ).
  - Oscillazioni  $Q_t$  legate ai cicli naturali.
- **Fluttuazione casuale.** Variazioni  $\varepsilon_t$  non spiegate dalle altre componenti.
  - In genere si richiede un rumore bianco ( $\mu = 0$  e  $\sigma$  costante).
- Si possono considerare anche altre componenti, come ad esempio la ciclicità economica.
  - Periodo di lunga durata.

# Media mobile

- La media mobile  $m_t(h)$  è calcolata come media aritmetica di  $h$  osservazioni consecutive di una serie  $\{y_t\}$ .
- *Media mobile centrata (h dispari)*


$$m_t(h) = \frac{y_{t+(h-1)/2} + y_{t+(h-1)/2-1} + \cdots + y_{t-(h-1)/2}}{h}$$

- *Media mobile centrata (h pari)*

$$m_t(h) = \frac{y_{t+h/2} + y_{t+h/2-1} + \cdots + y_{t-h/2+1}}{2h} + \frac{y_{t+h/2-1} + y_{t+h/2-2} + \cdots + y_{t-h/2}}{2h}$$

- Media delle medie mobili centrate in  $(t-1/2)$  e  $(t+1/2)$  su  $h/2$  osservazioni
- Può essere impiegata per effettuare previsioni.

# Media mobile per consumo energia



# Scomposizione di una serie

- Attività di analisi e comprensione del fenomeno.
- Si postula la forma della funzione  $g$  che indica la dipendenza della serie dalle sue componenti.

➤ *Modello additivo*

$$Y_t = M_t + Q_t + \varepsilon_t$$

➤ *Modello moltiplicativo*

$$Y_t = M_t \times Q_t \times \varepsilon_t$$

- Altri modelli possibili
  - Es. Modello di Winters

# 1. Rimozione della tendenza

- Si calcola la media mobile centrata con  $h$  uguale alla stagionalità  $L$  del fenomeno, da cui la relazione:

$$M_t \approx m_t(h)$$

- In un modello moltiplicativo, si identifica la componente congiunta di stagionalità e fluttuazione casuale mediante il calcolo di  $\{B_t\}$ :

$$B_t = Q_t \epsilon_t = \frac{Y_t}{M_t} \approx \frac{Y_t}{m_t(L)}$$


- In alternativa, si può rimuovere la tendenza:

➤ Differenziando

$$D_t = Y_t - Y_{t-1}, \quad t \geq 2.$$

➤ Attraverso un modello di regressione della  $M_t$ .

# 1. Rimozione della tendenza



Rimozione moltiplicativa della tendenza della serie storica del consumo di energia elettrica

## 2. Identificazione della stagionalità

- In primo luogo bisogna valutare se la serie presenta una regolarità periodica.
  - L'esame visivo del grafico costituisce il punto di partenza.
- Il valore  $L$  della stagionalità è spesso suggerito dal fenomeno.
  - Per osservazioni mensili  $L = 12$ , dati giornalieri,  $L = 7$ , ...



## 2. Identificazione della stagionalità

- Si calcolano gli indici di stagionalità  $Q_l$ ,  $l=1, \dots, L$ , ottenuti come media dei  $Q_t \epsilon_t$  per i periodi omologhi ad  $l$ .
  - Se la stagionalità è in mesi, i periodi omologhi al mese di gennaio, sono tutti i gennaio compresi nell'orizzonte temporale.


- Posto:

$$Q_l = \frac{\sum_{t \in z_l} Q_t \epsilon_t}{|z_l|}$$

con  $z_l$  insieme degli indici dei periodi omologhi a  $l$ .


- La destagionalizzazione si calcola mediante  $y_t / Q_{l(t)}$ 
  - $l(t)$  indica il tipo di periodo corrispondente a  $t$ .

## 2. Identificazione della stagionalità



Indici di stagionalità per la serie storica del consumo di energia elettrica

# Rimozione della stagionalità



Destagionalizzazione e regressione per la serie storica del consumo di energia elettrica

# Modelli di predizione

- I modelli di smoothing esponenziale sono tra i modelli predittivi per l'analisi di serie storiche più versatili ed accurati.
- Si sono dimostrati particolarmente adatti per la previsione di fenomeni di natura economica.
- Originariamente formulati su base empirica, hanno trovato adeguate giustificazioni teoriche.

# Modello di Brown

- *Modello di smoothing esponenziale semplice:*

$$s_t = \alpha y_{t-1} + (1-\alpha) s_{t-1}$$
$$s_1 = y_1, \alpha \in [0, 1]$$

- Si dimostra che:

$$f_{t+1} = \alpha y_t + \alpha(1-\alpha)y_{t-1} + \alpha(1-\alpha)^2 y_{t-2} + \dots + \alpha(1-\alpha)^{k-1} y_{t-k+1}$$

- Il valore del parametro  $\alpha$  è indice dell'inerzia del modello.

# Modello di Holt

- Il modello di Brown non è in grado di cogliere la tendenza presente tra le componenti della serie.
- La relazione ricorsiva viene quindi modificata con:

$$s_t = \alpha y_t + (1 - \alpha) (s_{t-1} + m_{t-1})$$

- Un'analoga relazione ricorsiva governa l'aggiornamento della tendenza smorzata:

$$m_t = \beta (s_t - s_{t-1}) + (1 - \beta) m_{t-1}$$

- La predizione per l'istante  $t + 1$  è:

$$f_{t+1} = s_t + m_t$$

# Modello di Winters

- Se nella serie è presente anche la stagionalità è necessario estendere i modelli precedenti.
- Se ogni ciclo è costituito da  $L$  periodi, si modificano gli aggiornamenti di  $m_t$  e  $s_t$  introducendo un aggiornamento della stagionalità:

$$s_t = \alpha \frac{y_t}{q_{t-L} - L} + (1 - \alpha)(s_{t-1} + m_{t-1})$$

$$m_t = \beta(s_t - s_{t-1}) + (1 - \beta)m_{t-1}$$

$$q_t = \gamma \frac{y_t}{s_t} + (1 - \gamma)q_{t-L}$$

- La previsione diventa quindi:

$$f_{t+1} = (s_t + m_t)q_{t-L+1}.$$

# Esercizi

- Generare un dataset sintentico per il consumo di bottiglie di vino *Ponter* negli anni 2000 2007 che abbia le seguenti caratteristiche moltiplicative:
  - Nel primo Trimestre ne sono state consumate 10K unità
  - Trend di crescita lineare del 10% all'anno
  - Stagionalità trimestrale tra [ 0.96, 1.03] con un aumento del 7% tra il primo e secondo mese e diminuzione del 4% tra secondo e terzo.
  - Errore bianco con ampiezza in [0.96, 1.04]
- Separare le componenti e valutare il modello determinato.
- Predirre il consumo di *Ponter* nel primo e secondo trimestre 2008.



# Sommario

- Abbiamo visto come alcuni fenomeni vengano descritti da serie storiche
- Abbiamo introdotto gli indici di valutazione
- Abbiamo scomposto le serie storiche in componenti
- Abbiamo derivato modelli di previsione
  - Modello di Brown
  - Modello di Holt
  - Modello di Winters

# Nella prossima lezione

- **Classificazione**
  - Valutazione
  - Alberi di classificazione
  - Metodi bayesiani
  - Regressione logistica
  - Reti neurali
  - Support vector machines