

Serie Storiche Economiche

7. Lisciamento esponenziale



La previsione

La previsione si basa sull'idea che l'informazione sul passato ci permetta di prevedere gli eventi futuri.

Tre elementi della previsione:

- l'orizzonte temporale
 - ▶ breve
 - ▶ medio
 - ▶ lungo
- l'obiettivo
 - ▶ strumentale
 - ▶ tendenziale (neutrale)
 - ▶ condizionale
 - ▶ normativa
- il metodo
 - ▶ informale
 - ▶ serie storiche
 - ▶ regressione e modelli econometrici



Lisciamento esponenziale

Il *lisciamento esponenziale* nasce nel 1957 come metodo pragmatico per la previsione delle serie storiche basato sulle medie mobili. In seguito esso è stato giustificato teoricamente anche nel quadro della teoria “moderna” delle serie storiche come caso particolare dei modelli ARMA/ARIMA.

- Si supponga di disporre, al tempo t , di una serie di osservazioni

$$y_{t-n}, y_{t-n+1}, \dots, y_{t-3}, y_{t-2}, y_{t-1}, y_t$$

e di voler prevedere y_{t+1}

- Si potrebbe pensare di ricorrere a una media mobile “all’indietro” di alcuni termini
- L’idea alla base del lisciamento esponenziale è di modificare l’approccio delle medie mobili attribuendo più importanza alle osservazioni più recenti e in particolare all’ultima y_t



Lisciamento esponenziale semplice

Il *lisciamento esponenziale costante* o *semplice* parte dall'ipotesi che la serie sia stazionaria in media

- In prima approssimazione, dato che la serie è stazionaria in media, si potrebbe prendere come previsore in $t + 1$ la media aritmetica delle osservazioni:

$$\hat{y}_{t+1} = \frac{\sum_{j=n}^0 y_{t-j}}{n}$$

ma così si darebbe lo stesso peso a ogni osservazione.

- Il lisciamento esponenziale semplice generalizza quanto sopra assegnando a ogni osservazione un peso:

$$\hat{y}_{t+1} = \frac{\sum_{j=n}^0 \omega_j y_{t-j}}{\sum_j \omega_j}$$

(nella media aritmetica è $\omega_j = \frac{1}{n} \forall j$)



Determinazione dei pesi

Nel modello di lisciamiento esponenziale costante si stabilisce che i pesi ω_j decrescono esponenzialmente fino a 0 al crescere della distanza da t .

- Si impone:

$$\omega_j = \alpha(1 - \alpha)^j$$

con $0 < \alpha < 1$ e $\sum^{\infty} \omega_j = 1$

- Sostituendo ricorsivamente ad ogni termine y_h la previsione fatta in $h - 1$: \hat{y}_h , si ottiene il seguente modello:

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha)\hat{y}_t$$

dove α è chiamato *parametro di lisciamiento* (smoothing).



Il lisciamento esponenziale come correzione sequenziale degli errori di previsione

Si vede come il modello si fondi su una logica di *aggiornamento sequenziale*:

- la previsione a un passo \hat{y}_{t+1} è una media dell'ultimo termine e di tutti i precedenti, sintetizzati nella previsione precedente \hat{y}_t .
- Inoltre, riscrivendo la formula come

$$\hat{y}_{t+1} = \alpha y_t + \hat{y}_t - \alpha \hat{y}_t = \hat{y}_t + \alpha(y_t - \hat{y}_t)$$

si nota come la previsione corrente \hat{y}_{t+1} sia uguale alla precedente \hat{y}_t modificata per l'errore di previsione $(y_t - \hat{y}_t)$ commesso al passo precedente, moltiplicato per il parametro di smussamento α .

Si adotta pertanto una logica di correzione sequenziale degli errori di previsione.



Come scegliere il parametro α ?

A questo punto, rimane libero il parametro α :

- il criterio di *ottimalità* per la sua stima dovrà essere basato sull'impiego pratico del modello
- pertanto è naturale cercare $\hat{\alpha}$ tale da “minimizzare gli errori di previsione”, per esempio sotto forma di somma dei quadrati:

$$\min_{\hat{\alpha}} SS(\hat{\alpha}) = \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

la stima viene ottenuta con metodi numerici (p. es. *grid search*)

- un altro problema (minore) è come *inizializzare* la serie dei valori previsti, ovvero cosa sostituire per \hat{y}_1 : si può usare y_1 o una media dei primi valori.



Il metodo di Holt e Winters

Consideriamo una serie storica non stazionaria in media, che ammette

- un trend
- una componente stagionale

Se la serie storica ammette una tendenza di fondo *localmente rettilinea*, un modo di adattare il lisciamiento esponenziale al caso è di scomporre il valore y_{t+1} in

- un livello medio in t , L_t , e
- un trend T_t tra il tempo t e $t + 1$

In generale, su un intervallo di lunghezza Θ , il valore previsto della serie al tempo $t + \Theta$ sarà esprimibile come

$$\hat{y}_{t+\Theta} = \hat{L}_t + \hat{T}_t\Theta$$



Il metodo di Holt e Winters: stima - 1

Anziché stimare congiuntamente le due componenti, si scompone il procedimento utilizzando due modelli di lisciamento esponenziale:

- uno per il livello medio

$$\hat{L}_t = (1 - \alpha)y_t + \alpha(\hat{L}_{t-1} + \hat{T}_{t-1})$$

- e uno per il trend

$$\hat{T}_t = \beta \hat{T}_{t-1} + (1 - \beta)(\hat{L}_t - \hat{L}_{t-1})$$

dove il primo modello ricostruisce, secondo il solito processo ricorsivo/di correzione dell'errore, il livello medio, il secondo il trend (il cui valore osservato T_t è definito come differenza tra i livelli medi).

Il metodo di Holt e Winters: stima - 2

Nel caso vi fosse una componente stagionale *additiva*, ovvero

$$\hat{y}_{t+\Theta} = \hat{L}_t + \hat{T}_t\Theta + \hat{S}_{t+\Theta-s}$$

si aggiungerebbe una terza equazione:

- livello medio:

$$\hat{L}_t = \alpha(\hat{L}_{t-1} + \hat{T}_{t-1}) + (1 - \alpha)(\bar{y}_t - \hat{S}_{t-s})$$

- trend:

$$\hat{T}_t = \beta\hat{T}_{t-1} + (1 - \beta)(\hat{L}_t - \hat{L}_{t-1})$$

- stagionalità:

$$\hat{S}_t = \gamma\hat{S}_{t-s} + (1 - \gamma)(\tilde{y}_t - \hat{L}_t)$$

dove nell'equazione del livello medio \bar{y}_t è il valore *destagionalizzato* di y_t , e nell'equazione della stagionalità \tilde{y} è il valore *detrendizzato* di y_t .



Il metodo di Holt e Winters: stima - 3

Nel caso vi fosse una componente stagionale *moltiplicativa*, ovvero

$$\hat{y}_{t+\Theta} = [\hat{L}_t + \hat{T}_t\Theta]\hat{S}_{t+\Theta-s}$$

- livello medio:

$$\hat{L}_t = \alpha(\hat{L}_{t-1} + \hat{T}_{t-1}) + (1 - \alpha)\frac{\bar{y}_t}{\hat{S}_{t-s}}$$

- trend:

$$\hat{T}_t = \beta\hat{T}_{t-1} + (1 - \beta)(\hat{L}_t - \hat{L}_{t-1})$$

- stagionalità:

$$\hat{S}_t = \gamma\hat{S}_{t-s} + (1 - \gamma)\frac{\tilde{y}_t}{\hat{L}_t}$$



Valutazione della qualità delle previsioni

Per valutare la qualità delle previsioni si fa spesso ricorso alla divisione del campione in

- dataset di *training*
- dataset di *test*

In generale, processi formali di valutazione della bontà delle previsioni necessitano di:

- un vettore di valori *previsti* $p = [p_1, \dots, p_n]'$
- un vettore di valori *realizzati* $r = [r_1, \dots, r_n]'$

Previsione dei punti di svolta

In prima approssimazione, risulta interessante valutare la frequenza di corretta previsione dei *punti di svolta*. Definiamo *punto di svolta superiore* per una serie x_t il periodo t :

$$x_{t-1} < x_t, x_t > x_{t+1}$$

e *punto di svolta inferiore* per una serie x_t il periodo t :

$$x_{t-1} > x_t, x_t < x_{t+1}$$

Preso il totale, consideriamo la frequenza delle previsioni corrette e quelle degli errori

- di “prima specie” (svolta prevista ma non realizzata) n_{12}
- di “seconda specie” (viceversa) n_{21}

e costruiamo una tabella di contingenza.



Previsione dei punti di svolta - 2

p_t :	r_t : p.s.	no p.s.	Totale
p.s.	n_{11}	n_{12}	n_1
no p.s.	n_{21}	n_{22}	n_2
Totale	n_1	n_2	n

Definiamo *indice relativo degli errori di I specie* il rapporto tra questi e il totale dei punti di svolta previsti:

$$E_1 = \frac{n_{12}}{n_1}$$

e *indice relativo degli errori di II specie* il rapporto tra questi e il totale dei punti di svolta realizzati:

$$E_1 = \frac{n_{21}}{n_2}$$

Indici dell'errore medio di previsione

Per *errore di previsione* intendiamo $e_t = p_t - r_t$; per sintetizzare gli e_t usiamo una funzione monotona non decrescente degli stessi che assuma valore 0 solo se $e_t = 0 \forall t$.

Per esempio, l'*errore medio assoluto* di previsione

$$EAM = \frac{1}{n} \sum_{t=1}^n |e_t|$$

che rispetto al semplice *errore medio* $EM = \frac{1}{n} \sum_{t=1}^n e_t$ evita la compensazione di positivi e negativi: solo se vi è sistematicità negli errori di previsione sarà $EM \sim EAM$.



Mean square error (MQE)

La *media quadratica degli errori di previsione* (internazionalmente, Mean Square Error o MSE)

$$\sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$$

è un caso particolare della media potenziata $I_s = \left(\frac{1}{n} \sum_{t=1}^n e_t^2\right)^{1/s}$

Il quadrato del MQE/MSE si lascia scomporre in

$$MQE^2 = (\bar{p} - \bar{r})^2 + (\sigma_p - \sigma_r)^2 + 2\sigma_p\sigma_r(1 - \rho_{pr})$$

dove si vede che l'errore di previsione è dovuto a:

- diverse medie di p e r (*errore sistematico*)
- diverse variabilità di p e r (*errore nelle variabilità*)
- imperfetta correlazione lineare tra p e r (*errore nelle covarianze*)



Confronti tra indici di bontà previsiva

Per confrontare tra loro indici di bontà previsiva bisogna standardizzarli, p. es. usando l'*indice di Theil*:

$$U = \frac{MQE}{\sqrt{\frac{1}{n} \sum_{t=1}^n r_t^2}} = \sqrt{\frac{\sum_{i=1}^n (p_t - r_t)^2}{\sum_{i=1}^n r_t^2}}$$

Per confrontare invece le performance di un previsore su due sotto-intervalli si usa l'*indice di Giano*:

$$J = \frac{\frac{1}{n_2} \sum_{t=n_1+1}^{n_2} e_t^2}{\frac{1}{n_1} \sum_{t=1}^{n_1} e_t^2}$$

che assume valori maggiori di 1 se la capacità previsiva peggiora.



