

# Econometria | 2023/2024

## Lezione 10: Nonlinearità - Interazioni

---

**Giuseppe Ragusa**

<https://gragusa.org>

Roma, Marzo 2024



# Interazioni fra variabili

Spesso è interessante capire come l'effetto su  $Y$  di una variabile indipendente dipende dal valore di un'altra variabile.

## Domanda:

è possibile che scuole con molti studenti che apprendono l'inglese  $Elpct$  traggono più vantaggi da una riduzione delle dimensioni delle classi rispetto a quelle con un numero inferiore di studenti non-madrelingua?

Per rispondere si può usare una regressione multipla con un termine di **interazione**.

# Interazioni

Prendiamo in considerazione tre casi:

1. Interazioni tra due variabili binarie.
2. Interazioni tra una variabile binaria e una continua.
3. Interazioni tra due variabili continue.

# Interazioni tra due variabili binarie

Prendiamo due variabili binarie  $D_1$  e  $D_2$  e il modello di regressione della popolazione:

$$Y_i = \beta_0 + \beta_1 \times D_{1i} + \beta_2 \times D_{2i} + u_i,$$

dove

- $Y_i = \ln(\text{salari}_i)$ ,
- $D_{1i} = \{1 \text{ se la persona } i \text{ ha una laurea, } 0 \text{ altrimenti}\}$ .
- $D_{2i} = \{1 \text{ se la persona } i \text{ è donna, } 0 \text{ se la persona } i\text{-esima è uomo}\}$ .

Sappiamo che  $\beta_1$  misura la differenza media tra individui con e senza laurea e  $\beta_2$  è la differenza, **ceteris paribus**, di genere in  $\log(\text{salari})$ .

Questo modello non ci permette di determinare se esiste un effetto specifico di genere nel possedere una laurea e, in caso affermativo, quanto sia forte questo effetto.

# Interazioni tra due variabili binarie, ctd.

Consideriamo invece il seguente modello:

$$Y_i = \beta_0 + \beta_1 \times D_{1i} + \beta_2 \times D_{2i} + \beta_3(D_{1i} \times D_{2i}) + u_i$$

$D_{1i} \times D_{2i}$  è il termine di **interazione** e  $\beta_3$  misura la differenza nell'effetto (sui salari) di avere una laurea tra donne e uomini

Per interpretare i coefficienti, calcoliamo i valori attesi di Y per ogni possibile combinazione delle variabili binarie:

- $D_1 = 0$  e  $D_2 = 0$  :  $E(Y|D_1 = 0, D_2 = 0) = \beta_0$
- $D_1 = 1$  e  $D_2 = 0$  :  $E(Y|D_1 = 1, D_2 = 0) = \beta_0 + \beta_1$
- $D_1 = 0$  e  $D_2 = 1$  :  $E(Y|D_1 = 0, D_2 = 1) = \beta_0 + \beta_2$
- $D_1 = 1$  e  $D_2 = 1$  :  $E(Y|D_1 = 1, D_2 = 1) = \beta_0 + \beta_1 + \beta_2 + \beta_3$

Ora possiamo confrontare questi valori attesi e interpretare i coefficienti.

# Interazioni tra due variabili binarie, ctd.

- $\beta_1$  è la differenza tra i valori attesi di  $Y$  quando  $D_1$  passa da 0 a 1, mentre  $D_2 = 0$ :

$$E(Y|D_1 = 1, D_2 = 0) - E(Y|D_1 = 0, D_2 = 0) = \beta_1$$

- $\beta_2$  è la differenza tra i valori attesi di  $Y$  quando  $D_2$  passa da 0 a 1, mentre  $D_1 = 0$ :

$$E(Y|D_1 = 0, D_2 = 1) - E(Y|D_1 = 0, D_2 = 0) = \beta_2$$

- $\beta_1 + \beta_3$  è la differenza tra i valori attesi di  $Y$  quando  $D_1$  passa da 0 a 1, mentre  $D_2 = 1$ :

$$E(Y|D_1 = 1, D_2 = 1) - E(Y_i|D_1 = 0, D_2 = 1) = \beta_1 + \beta_3$$

- $\beta_2 + \beta_3$  è la differenza tra i valori attesi di  $Y$  quando  $D_2$  passa da 0 a 1, mentre  $D_1 = 1$ :

$$E(Y|D_1 = 1, D_2 = 1) - E(Y_i|D_1 = 1, D_2 = 0) = \beta_2 + \beta_3$$

# Esempio: **HiSTR** e **HiEL**

$$HiSTR = \begin{cases} 1, & \text{se } STR \geq 20 \\ 0, & \text{altrimenti,} \end{cases}, \quad HiEL = \begin{cases} 1, & \text{se } PctEL \geq 10 \\ 0, & \text{altrimenti.} \end{cases}$$

Possiamo costruire le variabili sopra utilizzando **R** nel seguente modo:

```
1 library(Ecdat)
2 library(dplyr)
3 data(Caschool)
4 # Aggiungiamo HiSTR e HiEL CASchool
5 Caschool <- Caschool |> mutate(HiSTR = ifelse(str >= 20, 1, 0),
6                               HiEL = ifelse(elpct >= 10, 1, 0))
```

Procediamo quindi stimando il modello

$$TestScore = \beta_0 + \beta_1 \times HiSTR + \beta_2 \times HiEL + \beta_3 \times (HiSTR \times HiEL) + u_i.$$

Esistono diversi modi per aggiungere il termine di interazione alla formula quando si utilizza `lm()` o `feols()` — ma il modo più intuitivo è utilizzare **HiEL\*HiSTR**.<sup>1</sup>

1. Aggiungendo **HiEL\*HiSTR** alla formula, verranno aggiunti **HiEL**, **HiSTR** e la loro interazione come regressori, mentre **HiEL:HiSTR** aggiunge solo il termine di interazione.

# Esempio: HiSTR e HiEL, ctd

$$TestScore = \beta_0 + \beta_1 \times HiSTR + \beta_2 \times HiEL + \beta_3 \times (HiSTR \times HiEL) + u_i.$$

```
1 library(fixest)
2 # stimiamo il modello con un termine di interazione binaria
3 bi_model <- feols(testscr ~ HiSTR * HiEL, data = Caschool, vcov = "hetero")
4 summary(bi_model)
```

```
OLS estimation, Dep. Var.: testscr
Observations: 420
Standard-errors: Heteroskedasticity-robust
```

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	664.14329	1.38809	478.458830	< 2.2e-16 ***
HiSTR	-1.90784	1.93221	-0.987386	3.2403e-01
HiEL	-18.16295	2.34595	-7.742249	7.5024e-14 ***
HiSTR:HiEL	-3.49434	3.12123	-1.119539	2.6356e-01

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
RMSE: 16.0  Adj. R2: 0.290475
```

# Esempio: $HiSTR$ e $HiEL$ , ctd.

Il modello di regressione stimato è

$$\widehat{TestScore} = 664.1 - \underset{(1.39)}{1.9} \times HiSTR - 18.3 \times HiEL - \underset{(2.33)}{3.3} \times (HiSTR \times HiEL)$$

L'effetto del passaggio da un distretto scolastico con un basso rapporto studenti-insegnanti ( $HiStr = 0$ ) a uno con un alto rapporto studenti-insegnanti ( $HiStr = 1$ ), a seconda dell'alto o basso percentuale di studenti che parlano inglese, sia di  $-1.9 - 3.3 \times HiEL$ .

- per i distretti con una bassa percentuale di studenti che parlano inglese ( $HiEL = 0$ ), l'effetto previsto è una diminuzione di 1.9 punti
- per i distretti con una alta percentuale di studenti che parlano inglese ( $HiEL = 1$ ), l'effetto previsto è una diminuzione di  $1.9 + 3.3 = 5.2$  punti

# Interazioni tra variabile binaria e continua

Consideriamo adesso il caso in cui  $X_i$  è il numero di anni di esperienza lavorativa della persona  $i$ , una variabile continua. Abbiamo

$$Y_i = \ln(\text{salari}_i),$$

$$X_i = \text{esperienza lavorativa della persona } i,$$

$$D_i = \begin{cases} 1, & \text{se la persona } i\text{-esima ha una laurea universitaria} \\ 0, & \text{altrimenti.} \end{cases}$$

Il modello è quindi

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + u_i,$$

Questo modello ci consente di stimare il beneficio medio di avere una laurea universitaria (tenendo costante l'esperienza lavorativa) e l'effetto medio dell'esperienza lavorativa sui salari (tenendo costante la laurea universitaria)

# Interazioni tra variabile binaria e continua, ctd.

Aggiungendo il termine di interazione  $X_i \times D_i$ , consentiamo all'effetto di un anno aggiuntivo di esperienza lavorativa di differire tra individui con e senza laurea universitaria,

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + \beta_3 (X_i \times D_i) + u_i.$$

Qui,  $\beta_3$  rappresenta la differenza attesa nell'effetto di un anno aggiuntivo di esperienza lavorativa tra laureati e non laureati.

Un'altra possibile specificazione è

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 (X_i \times D_i) + u_i.$$

Secondo questo modello l'impatto atteso di un anno aggiuntivo di esperienza lavorativa sui guadagni differisce tra laureati e non laureati ma la laurea di per sé non aumenta i guadagni.

# Interazioni tra variabile binaria e continua

Un termine di interazione come  $X_i \times D_i$  (dove  $X_i$  è continuo e  $D_i$  binario) consente alla pendenza di dipendere dalla variabile binaria  $D_i$ .

Ci sono tre possibilità:

1. Intercetta diversa e stessa pendenza:

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + u_i$$

2. Intercetta diversa e pendenza diversa:

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + \beta_3 \times (X_i \times D_i) + u_i$$

3. Stessa Intercetta e pendenza diversa:

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 (X_i \times D_i) + u_i$$

# Esempio: `str` e `HiEL`

Possiamo rispondere alla domanda se l'effetto sulla punteggio dei test di ridurre il rapporto studenti-insegnanti dipenda dal fatto che ci siano molti o pochi studenti non-madrelingua usando `str` invece di `HiSTR`.

Stimiamo il modello di regressione

$$\widehat{TestScore}_i = \beta_0 + \beta_1 \times str_i + \beta_2 \times HiEL_i + \beta_3 (str_i \times HiEL_i) + u_i.$$

```
1 bci_model <- feols(testscr ~ str + HiEL + str * HiEL, data = Caschool, vcov = "hetero")
2 summary(bci_model)
```

```
OLS estimation, Dep. Var.: testscr
Observations: 420
Standard-errors: Heteroskedasticity-robust

```

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	682.245839	11.867814	57.487067	< 2.2e-16 ***
str	-0.968460	0.589102	-1.643961	0.10094
HiEL	5.639141	19.514556	0.288971	0.77275
str:HiEL	-1.276613	0.966919	-1.320289	0.18746

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
RMSE: 15.8  Adj. R2: 0.305368
```

# Esempio: *str* e *HiEL*, ctd.

The estimated regression model is

$$\widehat{TestScore} = 682.2 - 0.97 \times size + 5.6 \times HiEL - 1.28 \times (size \times HiEL).$$

(11.87)      (0.59)                      (19.51)                      (0.97)

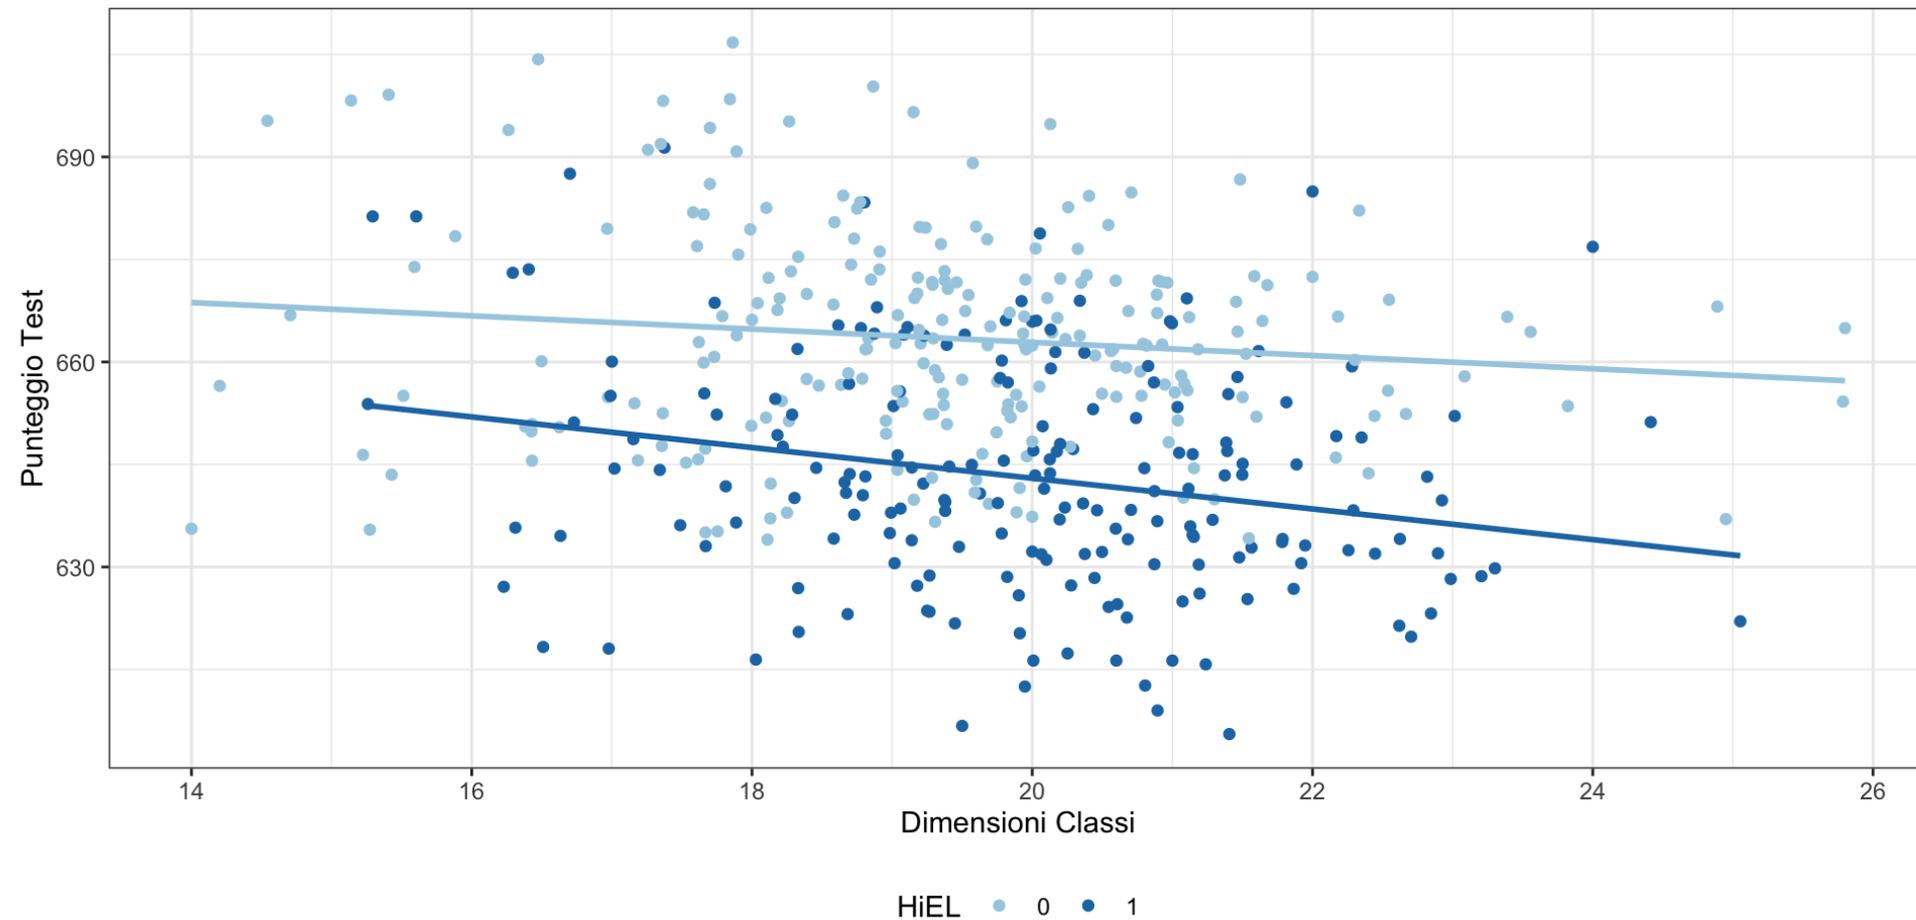
La retta di regressione stimata per i distretti con una bassa frazione di studenti non-madrelingua ( $HiEL_i = 0$ ) è:

$$\widehat{TestScore} = 682.2 - 0.97 \times str_i.$$

Per i distretti con una grande frazione di studenti non-madrelingua abbiamo invece:

$$\begin{aligned}\widehat{TestScore} &= 682.2 + 5.6 - 0.97 \times str_i - 1.28 \times str_i \\ &= 687.8 - 2.25 \times str_i.\end{aligned}$$

# Esempio: **str** e **HiEL**, ctd.



# Interazioni tra due variabili continue

Consideriamo adesso un modello di regressione con  $Y$  come logaritmo dei guadagni e due regressori continui  $X_1$ , gli anni di esperienza lavorativa, e  $X_2$ , gli anni di istruzione.

Vogliamo stimare l'effetto sui salari di un anno aggiuntivo di esperienza lavorativa a seconda di un determinato livello di istruzione. Questo effetto può essere valutato includendo il termine di interazione ( $X_{1i} \times X_{2i}$ ) nel modello:

$$\Delta Y_i = \beta_0 + \beta_1 \times X_{1i} + \beta_2 \times X_{2i} + \beta_3 \times (X_{1i} \times X_{2i}) + u_i$$

L'effetto su  $Y$  di una variazione di  $X_1$  tenendo costante  $X_2$  is

$$\frac{\Delta Y}{\Delta X_1} = \beta_1 + \beta_3 X_2.$$

Un valore positivo di  $\beta_3$  implica che l'effetto sul logaritmo dei salari di un anno aggiuntivo di esperienza lavorativa **cresce** linearmente con gli anni di istruzione.

# Interazioni tra due variabili continue, ctd.

Abbiamo anche che

$$\frac{\Delta Y}{\Delta X_2} = \beta_2 + \beta_3 X_1$$

come l'effetto su logaritmo dei salari di un anno aggiuntivo di istruzione mantenendo costante l'esperienza lavorativa.

Complessivamente, troviamo che  $\beta_3$  misura l'effetto di un aumento unitario in  $X_1$  e  $X_2$  **oltre** gli effetti di aumentare  $X_1$  da solo e  $X_2$  da solo di una unità.

La variazione complessiva in  $Y$  è quindi

$$\frac{\Delta Y}{\Delta X_1} = \beta_1 + \beta_3 X_2, \quad \frac{\Delta Y}{\Delta X_2} = \beta_2 + \beta_3 X_1, \quad \frac{\Delta Y}{\Delta X_1 \Delta X_2} = \beta_3.$$

# Esempio: *str* e *elpct*

Possiamo rispondere alla domanda se l'effetto sulla punteggio dei test di una diminuzione del rapporto studenti-insegnanti dipenda dal numero di studenti che apprendono l'inglese utilizzando le variabili continue *str* e *elpct*.

Stimiamo il modello

$$\widehat{TestScore}_i = \beta_0 + \beta_1 \times str_i + \beta_2 \times elpct_i + \beta_3(str_i \times elpct_i) + u_i.$$

```
1 # Stimiamo il modello
2 bci_model <- feols(testscr ~ str + elpct + str * elpct, data = Caschool, vcov = "hetero")
3 summary(bci_model)
```

```
OLS estimation, Dep. Var.: testscr
Observations: 420
Standard-errors: Heteroskedasticity-robust
      Estimate Std. Error   t value   Pr(>|t|)
(Intercept) 686.338525  11.759345  58.365370 < 2.2e-16 ***
str          -1.117018   0.587514  -1.901264  0.057958 .
elpct        -0.672911   0.374123  -1.798636  0.072801 .
str:elpct     0.001162   0.018536   0.062676  0.950054
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
RMSE: 14.4  Adj. R2: 0.422299
```

$$\widehat{TestScore} = 686.3 - 1.12 \times str - 0.67 \times elpct + 0.0012 \times (str \times elpct).$$

(11.76)
(0.59)
(0.37)
(0.02)

Per l'interpretazione, consideriamo i quartili di `elpct`

```
1 summary(Caschool$elpct)
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.000	1.941	8.778	15.768	22.970	85.540

- Se `elpct` è al suo valore mediano di 8.78, stimiamo una pendenza di  $-1.12 + 0.0012 \times 8.78 = -1.11$  che significa che aumentare il rapporto studenti-insegnanti di una unità deteriora i punteggi dei test di 1.11 punti.
- Se `elpct` è al 75 quantile, un aumento di una unità di `str` è  $-1.12 + 0.0012 \times 23.0 = -1.09$ , quindi la pendenza è leggermente inferiore. L'interpretazione: in un distretto scolastico con una quota di studenti non-madrelingua del 23, una riduzione di `STR` di una unità è associato ad una diminuzione dei punteggi dei test di circa 1.09 punti.

Tuttavia, la differenza dell'effetto per diversi valori di `elpct` non è statisticamente significativa. Infatti, non è possibile respingere l' $H_0 : \beta_3 = 0$ .