

Metodi Statistici per le decisioni

2024-2025


Vincenzo Nardelli



vincenzo.nardelli@unicatt.it




Regressione Lineare

- ▶ La regressione lineare è un approccio semplice per l'apprendimento supervisionato. Assume che la dipendenza di Y da X_1, X_2, \dots, X_p sia lineare.



- ▶ Anche se può sembrare troppo semplicistico, la regressione lineare è estremamente utile sia concettualmente che praticamente.

Dati pubblicitari



Regressione lineare per i dati pubblicitari

Domande che potremmo porci:


- ▶ Esiste una relazione tra budget pubblicitario e vendite?
- ▶ Quanto è forte la relazione tra budget pubblicitario e vendite?
- ▶ Quali mezzi contribuiscono alle vendite?
- ▶ Con quanta accuratezza possiamo prevedere le vendite future?
- ▶ La relazione è lineare?
- ▶ Esiste sinergia tra i mezzi pubblicitari?

Regressione lineare semplice con un singolo predittore X

Assumiamo un modello

$$Y = \beta_0 + \beta_1 X + \epsilon,$$

dove β_0 e β_1 sono due costanti sconosciute che rappresentano l'*intercetta* e la *pendenza*, noti anche come *coefficienti* o *parametri*, e ϵ è il termine di errore.




Regressione lineare semplice con un singolo predittore X

Dati alcuni valori stimati $\hat{\beta}_0$ e $\hat{\beta}_1$ per i coefficienti del modello, prevediamo le vendite future usando

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x,$$

dove \hat{y} indica una previsione di Y sulla base di $X = x$. Il simbolo con il cappello denota un valore stimato.

Sia $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$ la previsione per Y basata sul valore i-esimo di X. Allora $e_i = y_i - \hat{y}_i$ rappresenta il residuo i-esimo.



Stima dei parametri tramite minimi quadrati

- Definiamo la *somma dei quadrati dei residui* (RSS) come

$$\text{RSS} = e_1^2 + e_2^2 + \dots + e_n^2,$$

o equivalentemente come

$$\text{RSS} = (y_1 - \hat{\beta}_0 - \hat{\beta}_1 x_1)^2 + (y_2 - \hat{\beta}_0 - \hat{\beta}_1 x_2)^2 + \dots + (y_n - \hat{\beta}_0 - \hat{\beta}_1 x_n)^2.$$

Stima dei parametri tramite minimi quadrati

- Definiamo la *somma dei quadrati dei residui* (RSS) come

$$\text{RSS} = e_1^2 + e_2^2 + \dots + e_n^2,$$

o equivalentemente come

$$\text{RSS} = (y_1 - \hat{\beta}_0 - \hat{\beta}_1 x_1)^2 + (y_2 - \hat{\beta}_0 - \hat{\beta}_1 x_2)^2 + \dots + (y_n - \hat{\beta}_0 - \hat{\beta}_1 x_n)^2.$$

- L'approccio dei minimi quadrati sceglie $\hat{\beta}_0$ e $\hat{\beta}_1$ per minimizzare l'RSS. I valori che minimizzano possono essere mostrati come

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x},$$


dove $\bar{y} \equiv \frac{1}{n} \sum_{i=1}^n y_i$ e $\bar{x} \equiv \frac{1}{n} \sum_{i=1}^n x_i$ sono le medie campionarie.

Valutazione dell'Accuratezza Complessiva del Modello

- Il *R-quadrato* o frazione della varianza spiegata è

$$R^2 = \frac{TSS - RSS}{TSS} = 1 - \frac{RSS}{TSS}$$

dove $TSS = \sum_{i=1}^n (y_i - \bar{y})^2$ è la *somma totale dei quadrati*.



LAB Consumo di Sigarette

Un ente sanitario sta studiando come il prezzo e la tassazione influenzino il consumo di sigarette a livello statale. Analizzando i dati storici, l'obiettivo è comprendere l'efficacia delle politiche di aumento dei prezzi e delle tasse sul controllo del consumo di tabacco. Questa analisi fornirà basi solide per formulare raccomandazioni a favore della salute pubblica, con l'intento di ridurre il consumo di sigarette e i rischi correlati alla salute.

Attraverso lo studio di queste relazioni, l'ente sanitario intende valutare l'effetto delle variazioni di prezzo e tassazione per pianificare strategie che possano incentivare un decremento nel consumo di sigarette.

Descrizione delle Variabili - Dataset Cigarette (Pacchetto Ecdat)

Il dataset contiene informazioni raccolte a livello statale negli Stati Uniti e include variabili chiave per l'analisi dell'effetto dei prezzi e della tassazione sul consumo di sigarette. Le principali variabili sono:

- ▶ **state**: Stato in cui sono stati raccolti i dati.
- ▶ **year**: Anno della raccolta dei dati.
- ▶ **avgprs**: Prezzo medio di un pacchetto di sigarette (in dollari).
- ▶ **packpc**: Consumo di sigarette (pacchetti pro capite).
- ▶ **taxs**: Totale delle tasse su un pacchetto di sigarette (in dollari).

LAB Consumo di Sigarette: Domande di Analisi

- ▶ Esiste una relazione tra il prezzo medio di un pacchetto di sigarette ($avgprs$) e il consumo di sigarette ($packpc$)? La relazione è positiva o negativa?
- ▶ Qual è la correlazione tra prezzo medio e consumo di sigarette? Come possiamo interpretare questo valore per valutare l'influenza del prezzo sul consumo?
- ▶ In che modo la tassazione totale ($taxs$) influenza il consumo di sigarette? Analizza questa relazione utilizzando uno scatterplot e calcola la correlazione.
- ▶ Tramite un modello di regressione lineare, quale sarebbe l'impatto sui consumi di sigarette se la tassazione in uno stato passasse da 50\$ a 100\$?

Un'agenzia immobiliare è interessata a comprendere come il livello socioeconomico di una zona influenzi il valore medio delle case di Boston. L'obiettivo è valutare l'impatto del livello di povertà sul valore medio delle abitazioni, così da poter offrire raccomandazioni più precise agli investitori e ai pianificatori urbani. L'analisi di questa

relazione è fondamentale per definire strategie di investimento mirate e per prevedere l'andamento del mercato immobiliare in funzione delle variabili socioeconomiche, contribuendo a migliorare l'efficacia delle decisioni di business.

Descrizione delle Variabili - Dataset Boston (Pacchetto ISLR2)

Il dataset contiene informazioni su vari quartieri, includendo variabili chiave per l'analisi socioeconomica del valore delle abitazioni. Di seguito alcune delle principali variabili utilizzate:

- ▶ **lstat**: Percentuale di popolazione con basso livello socioeconomico, un indicatore del livello di povertà nella zona.
- ▶ **medv**: Valore medio delle abitazioni in migliaia di dollari, rappresenta il target di interesse per il mercato immobiliare.
- ▶ **rm**: Numero medio di stanze per abitazione, una misura della dimensione abitativa media in ciascun quartiere.
- ▶ **age**: Percentuale di abitazioni costruite prima del 1940, indica la vetustà del patrimonio immobiliare.
- ▶ **dis**: Distanza media dai centri di lavoro di Boston, importante per valutare l'accessibilità ai servizi urbani.

LAB Real Estate: Domande di Analisi

- ▶ Qual è la relazione tra il livello di povertà ($1stat$) e il valore medio delle case ($medv$)? La relazione è positiva o negativa?
- ▶ Qual è la covarianza tra $1stat$ e $medv$? Che cosa ci indica questo valore?
- ▶ Qual è la correlazione tra $1stat$ e $medv$? Come si interpreta questa correlazione in termini di influenza del livello di povertà sui prezzi immobiliari?
- ▶ Possiamo prevedere il valore delle case in funzione del livello di povertà? Quali sono le previsioni del valore medio delle case per quartieri con livelli di povertà pari al 5%, 10%, e 15%?

LAB Real Estate: Visualizzazione dei Dati

- ▶ Qual è la distribuzione del livello di povertà ($lstat$) tra i quartieri? Visualizza e descrivi la distribuzione.
- ▶ Qual è la distribuzione del valore medio delle case ($medv$) tra i quartieri?
- ▶ Esiste una relazione lineare tra livello di povertà e valore medio delle case? Mostra il grafico e discuti i risultati.

LAB Real Estate: Analisi del Modello

- ▶ Quali sono i coefficienti di regressione tra livello di povertà e valore medio delle case? Come si interpretano l'intercetta e la pendenza?
- ▶ Qual è il livello di bontà di adattamento del modello? È una relazione forte o debole?
- ▶ In che modo possiamo utilizzare i risultati del modello per stimare il valore delle case in quartieri con livelli diversi di povertà?
- ▶ Prova a stimare altri modelli con le rimanenti variabili. Come si interpretano i risultati?

Errore Standard

- L'errore standard di un estimatore riflette come varia sotto campionamento ripetuto. Abbiamo:

$$\text{SE}(\hat{\beta}_1)^2 = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad \text{SE}(\hat{\beta}_0)^2 = \sigma^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right]$$

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

Intervalli di Confidenza

- ▶ Questi errori standard possono essere usati per calcolare intervalli di confidenza.
- ▶ Un intervallo di confidenza al 95% è definito come un intervallo che, con il 95% di probabilità, contiene il valore vero sconosciuto del parametro. Ha la forma:

$$\hat{\beta}_1 \pm 2 \cdot SE(\hat{\beta}_1)$$

Intervalli di Confidenza - Continuazione

- Cioè, c'è approssimativamente una probabilità del 95% che l'intervallo:

$$\left[\hat{\beta}_1 - 2 \cdot SE \left(\hat{\beta}_1 \right), \hat{\beta}_1 + 2 \cdot SE \left(\hat{\beta}_1 \right) \right]$$

contenga il valore vero di β_1 (in uno scenario in cui si ottengano campioni ripetuti come quello attuale).

Test di Ipotesi

- ▶ Gli errori standard possono essere utilizzati anche per eseguire test di ipotesi sui coefficienti.
- ▶ Il test più comune riguarda l'ipotesi nulla:

H_0 : Non c'è relazione tra X e Y

contro l'ipotesi alternativa:

H_A : C'è una relazione tra X e Y.

- ▶ Matematicamente, ciò corrisponde a testare:

$$H_0 : \beta_1 = 0, \quad H_A : \beta_1 \neq 0$$

poiché se $\beta_1 = 0$, il modello si riduce a $Y = \beta_0 + \epsilon$, e X non è associato a Y.

Test di Ipotesi - Continuazione

- ▶ Per testare l'ipotesi nulla, calcoliamo una statistica t, data da:

$$t = \frac{\hat{\beta}_1 - 0}{SE(\hat{\beta}_1)}$$

- ▶ Questa statistica ha una distribuzione t con $n - 2$ gradi di libertà, assumendo che $\beta_1 = 0$.
- ▶ Usando software statistici, è facile calcolare la probabilità di osservare un valore uguale o maggiore di $|t|$. Questa probabilità è chiamata p-value.

Risultati sui Dati di Pubblicità

	Coefficiente	Errore Std.	Statistica t	p-value
Intercetta	7.0325	0.4578	15.36	< 0.0001
TV	0.0475	0.0027	17.67	< 0.0001

Valutazione dell'Accuratezza Complessiva del Modello

- Calcoliamo l'Errore Standard Residuo (RSE):

$$\text{RSE} = \sqrt{\frac{1}{n-2} \text{RSS}} = \sqrt{\frac{1}{n-2} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

dove il residuo somma dei quadrati è:

$$\text{RSS} = \sum_{i=1}^n (y_i - \hat{y}_i)^2.$$

Risultati sui Dati di Pubblicità

Quantità	Valore
Errore Standard Residuo	3.26
R^2	0.612
Statistica F	312.1

Regressione Lineare Multipla

- ▶ Il modello è:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon$$

- ▶ Interpretiamo β_j come l'effetto medio su Y di un aumento unitario in X_j , mantenendo tutti gli altri predittori fissi. Nell'esempio pubblicitario, il modello diventa:

$$\text{vendite} = \beta_0 + \beta_1 \times \text{TV} + \beta_2 \times \text{radio} + \beta_3 \times \text{giornali} + \epsilon$$

Interpretazione dei Coefficienti di Regressione

- ▶ Lo scenario ideale è quando i predittori sono non correlati:
 - ▶ Ogni coefficiente può essere stimato e testato separatamente.
 - ▶ Interpretazioni come "un cambiamento unitario in X_j è associato a un cambiamento di β_j in Y , mentre tutte le altre variabili rimangono fisse" sono possibili.
- ▶ Attenzione alle correlazioni tra i predittori, possono causare problemi!

Stima e Predizione per la Regressione Multipla

- ▶ Date le stime $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$, possiamo fare previsioni usando la formula:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_p x_p$$

- ▶ Stimiamo $\beta_0, \beta_1, \dots, \beta_p$ come i valori che minimizzano la somma dei residui al quadrato:

$$\begin{aligned} \text{RSS} &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\ &= \sum_{i=1}^n \left(y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_p x_{ip} \right)^2 \end{aligned}$$

- ▶ Questo è fatto usando software statistici standard. I valori $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$ che minimizzano RSS sono le stime dei coefficienti di regressione multipla ottenuti con il metodo dei minimi quadrati.

Risultati per i Dati Pubblicitari

	Coefficiente	Errore Std.	Statistica t	p-value
Intercetta	2.939	0.3119	9.42	< 0.0001
TV	0.046	0.0014	32.81	< 0.0001
radio	0.189	0.0086	21.89	< 0.0001
giornali	-0.001	0.0059	-0.18	0.8599

Correlazioni

	TV	radio	giornali	vendite
TV	1.0000	0.0548	0.0567	0.7822
radio		1.0000	0.3541	0.5762
giornali			1.0000	0.2283
vendite				1.0000

Alcune domande importanti

1. Almeno uno dei predittori X_1, X_2, \dots, X_p è utile per prevedere la risposta?
2. Tutti i predittori aiutano a spiegare Y , o è utile solo un sottoinsieme?
3. Quanto bene il modello si adatta ai dati?
4. Dato un set di valori predittori, quale valore della risposta dobbiamo prevedere, e quanto è accurata la nostra previsione?

Almeno un predittore è utile?

- Per rispondere alla prima domanda, possiamo usare la statistica F:

$$F = \frac{(TSS - RSS)/p}{RSS/(n - p - 1)} \sim F_{p, n-p-1}$$

Quantità	Valore
Errore Standard Residuo	1.69
R ²	0.897
Statistica F	570

Valutazione dell'Accuratezza Complessiva del Modello: Confronto tra R^2 e R^2 adj

- ▶ Il R^2 è calcolato come:

$$R^2 = 1 - \frac{RSS}{TSS}$$

dove:

- ▶ $RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2$ è la somma dei quadrati dei residui.
 - ▶ $TSS = \sum_{i=1}^n (y_i - \bar{y})^2$ è la somma totale dei quadrati.
- ▶ Il R^2 *adj* tiene conto del numero di predittori e del numero di osservazioni, ed è calcolato come:

$$R_{adj}^2 = 1 - \frac{RSS/(n - p - 1)}{TSS/(n - 1)}$$

dove:

- ▶ n è il numero di osservazioni.
- ▶ p è il numero di predittori nel modello.

Decidere sulle variabili importanti

- ▶ L'approccio più diretto si chiama regressione con tutti i sottoinsiemi o migliori sottoinsiemi: calcoliamo la stima dei minimi quadrati per tutti i sottoinsiemi possibili e poi scegliamo in base a un criterio che bilancia l'errore di training con la dimensione del modello.
- ▶ Tuttavia, spesso non possiamo esaminare tutti i modelli possibili, dato che sono 2^p . Ad esempio, quando $p = 40$, ci sono più di un miliardo di modelli!
- ▶ Serve quindi un approccio automatizzato che cerchi tra un sottoinsieme di modelli. Discutiamo due approcci comunemente usati.

Selezione Avanti (Forward Selection)

- ▶ Inizia con il modello nullo: un modello che contiene un'intercetta ma nessun predittore.
- ▶ Adatta p regressioni lineari semplici e aggiungi al modello nullo la variabile che produce il minimo RSS.
- ▶ Aggiungi al modello la variabile che produce il minimo RSS tra tutti i modelli a due variabili.
- ▶ Continua finché non si soddisfa una regola di arresto, ad esempio quando tutte le variabili rimanenti hanno un p-value sopra una certa soglia.

Selezione Indietro (Backward Selection)

- ▶ Inizia con tutte le variabili nel modello.
- ▶ Rimuovi la variabile con il p-value più alto, cioè quella meno statisticamente significativa.
- ▶ Adatta il nuovo modello con $(p - 1)$ variabili e rimuovi la variabile con il p-value più alto.
- ▶ Continua finché non si raggiunge una regola di arresto. Ad esempio, si può arrestare quando tutte le variabili rimanenti hanno un p-value significativo rispetto a una soglia prestabilita.

Previsioni con il Modello Lineare

Equazione della previsione:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$$

Esempio pratico:

- ▶ Coefficienti stimati: $\hat{\beta}_0 = 5$, $\hat{\beta}_1 = 2$
- ▶ Per $x = 10$, si ottiene:

$$\hat{y} = 5 + 2 \cdot 10 = 25$$

Nota: La previsione è valida solo nel range dei dati osservati (*interpolazione*).

Valutazione tramite MSE

Errore Quadratico Medio (MSE):

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Interpretazione:

- ▶ Misura la distanza media quadratica tra i valori osservati (y_i) e quelli previsti (\hat{y}_i).
- ▶ Un MSE basso indica un buon adattamento del modello ai dati.

Rischi e Cose da Attenzione

Rischi delle Previsioni:

- ▶ **Overfitting:** Il modello si adatta troppo ai dati di training, perdendo capacità predittiva sui nuovi dati.
- ▶ **Estrapolazione:** Fare previsioni fuori dal range dei dati osservati può portare a risultati poco accurati.
- ▶ **Outlier:** Valori anomali nei dati possono influenzare negativamente il modello e aumentare l'MSE.

Cose da Attenzione:

- ▶ **Selezione delle variabili:** Utilizzare solo variabili rilevanti per ridurre il rumore nel modello.
- ▶ **Validazione del modello:** Valutare il modello su un set di dati di test per verificare la generalizzabilità.
- ▶ **MSE non contestualizzato:** Un MSE basso non garantisce che il modello sia utile; valutare anche il contesto dei dati.

Altre Considerazioni nel Modello di Regressione

Predittori Qualitativi

- ▶ Alcuni predittori non sono quantitativi ma qualitativi, assumendo un set discreto di valori.
- ▶ Questi sono anche chiamati predittori categorici o variabili fattoriali.
- ▶ Per esempio, dati sulle carte di credito.

Predittori Qualitativi - Continuazione

Esempio: Differenze nei saldi delle carte di credito tra uomini e donne, ignorando le altre variabili. Creiamo una nuova variabile:

$$x_i = \begin{cases} 1 & \text{se la persona } i \text{ è donna} \\ 0 & \text{se la persona } i \text{ è uomo} \end{cases}$$

Modello risultante:

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i = \begin{cases} \beta_0 + \beta_1 + \epsilon_i & \text{se la persona } i \text{ è donna} \\ \beta_0 + \epsilon_i & \text{se la persona } i \text{ è uomo} \end{cases}$$

Dati Carte di Credito - Continuazione

Risultati per il modello con genere:

	Coefficiente	Errore Std.	Statistica t	p-value
Intercetta	509.80	33.13	15.389	< 0.0001
genere[Femminile]	19.73	46.05	0.429	0.6690

Predittori Qualitativi con Più di Due Livelli

- ▶ Con più di due livelli, creiamo variabili dummy aggiuntive. Ad esempio, per la variabile etnia possiamo creare due variabili dummy. La prima potrebbe essere:

$$x_{i1} = \begin{cases} 1 & \text{se la persona } i \text{ è Asiatica} \\ 0 & \text{se la persona } i \text{ non è Asiatica} \end{cases}$$

e la seconda potrebbe essere:

$$x_{i2} = \begin{cases} 1 & \text{se la persona } i \text{ è Caucasica} \\ 0 & \text{se la persona } i \text{ non è Caucasica} \end{cases}$$

Predittori qualitativi con più di due livelli - Continuazione

- ▶ Entrambe queste variabili possono essere utilizzate nell'equazione di regressione, ottenendo il modello:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \epsilon_i = \begin{cases} \beta_0 + \beta_1 + \epsilon_i & \text{se la persona } i \text{ è Asiatica} \\ \beta_0 + \beta_2 + \epsilon_i & \text{se la persona } i \text{ è Caucasica} \\ \beta_0 + \epsilon_i & \text{se la persona } i \text{ è Afroamericana.} \end{cases}$$

- ▶ Ci sarà sempre una variabile dummy in meno rispetto al numero di livelli. Il livello senza variabile dummy (in questo esempio Afroamericano) è noto come **baseline**.

Risultati per l'etnia

	Coefficiente	Errore Std.	Statistica t	p-value
Intercetta	531.00	46.32	11.464	< 0.0001
etnia [Asiatica]	-18.69	65.02	-0.287	0.7740
etnia [Caucasica]	-12.50	56.68	-0.221	0.8260

LAB Credit Analysis

Una banca è interessata a comprendere quali fattori influenzano il saldo medio delle carte di credito dei clienti, con l'obiettivo di migliorare le decisioni sulle richieste di prestiti e crediti. L'analisi si focalizza su variabili socioeconomiche e comportamentali, come reddito, limite di credito e status da studente. L'obiettivo finale è fornire

raccomandazioni strategiche per ottimizzare la gestione del credito e ridurre i rischi finanziari, contribuendo a un processo decisionale più efficace.

Descrizione delle Variabili - Dataset Credit (Pacchetto ISLR2)

Il dataset contiene informazioni su clienti di una banca, incluse variabili chiave per l'analisi delle loro abitudini finanziarie e socioeconomiche. Di seguito alcune delle principali variabili utilizzate:

- ▶ **Balance:** Saldo medio della carta di credito, rappresenta la variabile target per l'analisi.
- ▶ **Income:** Reddito annuale del cliente (in migliaia di dollari), un indicatore della capacità di spesa.
- ▶ **Limit:** Limite massimo della carta di credito, rappresenta la disponibilità economica concessa dalla banca.
- ▶ **Rating:** Valutazione del cliente da parte della banca, in base alla sua storia creditizia.
- ▶ **Student:** Indica se il cliente è uno studente (variabile categorica).

LAB Credit Analysis: Analisi descrittiva

- ▶ Qual è la distribuzione del reddito (**In**come) tra i clienti? Visualizza e descrivi la distribuzione.
- ▶ Qual è la distribuzione del saldo medio delle carte di credito (**Ba**lance)?
- ▶ Qual è la relazione tra reddito (**In**come) e saldo medio della carta di credito (**Ba**lance)? La relazione è positiva o negativa?
- ▶ Qual è la covarianza tra **In**come e **Ba**lance? Che cosa ci indica questo valore?
- ▶ Qual è la correlazione tra **In**come e **Ba**lance? Come si interpreta questa correlazione in termini di influenza del reddito sul saldo della carta di credito?

LAB Credit Analysis: Modello

- ▶ Quali sono i coefficienti di regressione tra reddito e saldo medio? Come si interpretano l'intercetta e la pendenza?
- ▶ Possiamo prevedere il saldo medio della carta in funzione del reddito? Quali sono le previsioni del saldo per redditi pari a 20k, 50k, e 80k dollari?
- ▶ Qual è il livello di bontà di adattamento del modello (R^2)? È una relazione forte o debole?
- ▶ Includendo altre variabili come **Limit** e **Rating**, come cambia il modello? Quali variabili risultano più significative?
- ▶ In che modo la variabile categorica **Student** influisce sul saldo medio della carta di credito?

Cosa non abbiamo trattato

- ▶ Outlier
- ▶ Varianza non costante dei termini di errore
- ▶ Collinearità

Generalizzazione del Modello Lineare

- ▶ **Problemi di classificazione:** regressione logistica, support vector machines.
- ▶ **Non-linearità:** kernel smoothing, splines e modelli additivi generalizzati; metodi dei k-vicini più prossimi.
- ▶ **Interazioni:** metodi basati su alberi, bagging, foreste casuali e boosting (che catturano anche le non-linearità).
- ▶ **Fitting regolarizzato:** regressione Ridge e Lasso.