



SAPIENZA
UNIVERSITÀ DI ROMA

Dipartimento di Matematica
Corso di Laurea Magistrale in Matematica Applicata

Rielaborazione degli appunti del corso di

Elementi di Probabilità e statistica per Data Science

Simmaco Di Lillo
dsimmaco@gmail.com
a.a. 22-23

Introduzione

Queste note contengono i miei appunti personali presi durante il corso di "Elementi di Probabilità e statistica per Data Science" della Prof.ssa A. Faggionato e dunque non sono dispense ufficiali del corso.

Nelle note potrebbero essere presenti typo o errori, per qualsiasi segnalazione scrivetemi un'e-mail a dsimmaco@gmail.com, la versione aggiornata verrà caricata sul mio [sito](#)

Indice

1	Notazione e richiami	2
1.1	Richiami probabilistici	3
2	Numeri di ricoprimento e impacchettamento	4
2.1	Equivalenza tra i due numeri	5
2.2	Stime per sottoinsiemi di \mathbb{R}^n	6
3	Teorema di Glivenko-Cantelli	8
3.1	Disuguaglianza DWK	9
3.2	Classi di Glivenko-Cantelli	11
3.3	Applicazioni di Glivenko-Cantelli	12
4	Complessità di Rademacher	13
4.1	Discriminante polinomiale	19
5	Dimensione VC	21
6	Statistical Learning	23
7	Variabili aleatorie gaussiane e subgaussiane	26
7.1	Variabili aleatorie normali	26
7.2	Variabili aleatorie subgaussiane	27
7.3	Disuguaglianza di Hoeffding	31
8	Norme di matrici	34
8.1	Norma operatoriale per matrici	34
8.2	Norme di matrici subgaussiane	35
9	Teoria perturbativa di matrici simmetriche	37
10	Cluster Analysis	38
10.1	Two blocks models	38
10.2	Cluster Analysys	41
10.3	K-means	42
10.4	Unormalize Laplacian spectral cluster	44
11	Vettori aleatori	47
11.1	Vettori isotropi	47
11.2	Vettori e matrici gaussiane	49
12	Ampiezza sferica e gaussiana	50
13	Recovery problem	53
13.1	Recovery problem con rumore	54
14	Compressione di dati	56
15	Esercizi	59

1 Notazione e richiami

Andiamo a fissare alcune notazioni che verranno usate in seguito.

Se (K, d) è metrico, la palla di centro x e raggio ε è

$$B(x, \varepsilon) = B_\varepsilon(x) = \{y \in K : d(x, y) \leq \varepsilon\}$$

Se $x \in \mathbb{R}^d$ denotiamo con $\|x\|$ la norma euclidea, inoltre, se non diversamente specificato, considereremo sempre \mathbb{R}^d con la metrica euclidea.

$$S^{n-1} = \{x \in \mathbb{R}^d : \|x\| = 1\}$$

ovvero la sfera unitaria di \mathbb{R}^n

Definizione 1.1. Un insieme (X, \leq) è un insieme parzialmente ordinato se \leq è una relazione binaria con le seguenti caratteristiche

- riflessiva: $\forall x \in X$ vale $x \leq x$
- transitiva: $\forall x, y, z \in X$ vale $x \leq y$ e $y \leq z \Rightarrow x \leq z$
- antisimmetrica: $\forall x, y \in X$ vale $x \leq y$ e $y \leq x \Rightarrow x = y$

Se inoltre $\forall x, y \in X$ vale $x \leq y$ o $y \leq x$ diremo che l'insieme è **totalmente ordinato**

Definizione 1.2. Un sottoinsieme C di un insieme ordinato si dice **catena** se (C, \leq) è totalmente ordinato.

Un elemento di X che è maggiore di tutti gli elementi della catena si dice **maggiorante** per la catena.

Definizione 1.3. $y \in X$ è **massimale** se per ogni $x \in X$ con $y \leq x$ si ha $y = x$.

Lemma 1.1 (di Zorn). *Sia (X, \leq) un insieme non vuoto con un ordine parziale. Se ogni sua catena ha un maggiorante in X allora X contiene almeno un elemento massimale.*

Osservazione 1. Il lemma di Zorn è equivalente all'assioma di scelta

1.1 Richiami probabilistici

Definizione 1.4. Un **campione aleatorio** è una collezione di variabili aleatorie a valori in χ : X_1, \dots, X_n i.i.d.

Definizione 1.5. Se X è una variabile aleatoria a valori reali, la sua **funzione di ripartizione** è

$$F : \mathbb{R} \rightarrow [0, 1] \quad F(t) = \mathbb{P}(X \leq t)$$

Proposizione 1.2. Le funzioni di ripartizioni sono continue a destra con limite a sinistra, cioè

$$\exists f(t^-) = \lim_{t \rightarrow t^-} f(t)$$

e

$$f(t) = \lim_{t \rightarrow t^+} f(t)$$

Definizione 1.6. Se Y è vettore aleatorio in \mathbb{R}^n , la **funzione generatrice dei momenti** è

$$M_Y(t) = \mathbb{E} [e^{t \cdot Y}] \quad \forall t \in \mathbb{R}^n$$

Teorema 1.3. Siano X, Y vettori aleatori in \mathbb{R}^n allora

$$M_X = M_Y \quad \Rightarrow \quad X \sim Y$$

Teorema 1.4 (Legge forte dei grandi numeri). Sia $(X_n)_{n \in \mathbb{N}}$ una successione di variabili aleatorie definite sullo stesso spazio i.i.d con media μ . Per ogni n definiamo la media campionaria come

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

Allora con probabilità 1 si ha

$$\lim_{n \rightarrow +\infty} \bar{X}_n = \mu$$

Lemma 1.5 (di Borel Cantelli - prima parte). Sia (A_n) una successione di eventi.

$$\sum_{n \in \mathbb{N}} \mathbb{P}(A_n) < +\infty \quad \Rightarrow \quad P(A_n \text{ i.o.}) = 0$$

Teorema 1.6 (Disuguaglianza di Jensen). Sia X una v.a. reale con momento primo finito. Sia $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ convessa allora vale

$$\mathbb{E}[\varphi(X)] \geq \varphi(\mathbb{E}[X])$$

2 Numeri di ricoprimento e impacchettamento

Definizione 2.1. Sia (K, d) uno spazio metrico, dato $\varepsilon > 0$. Diremo che $A \subseteq K$ è un ε -**net** di K se

$$K \subseteq \bigcup_{x \in A} B(x, \varepsilon)$$

In altre parole,

$$\forall x \in K \quad \exists x_0 \in A \quad d(x, x_0) \leq \varepsilon$$

Osservazione 2. Per qualsiasi ε esiste un ε -net: tutto lo spazio è un ε -net.

Definizione 2.2. Il **numero di ricoprimento** (covering number) di K (di parametro ε) è definito come

$$N(K, d, \varepsilon) = \inf \{|A| : A \subseteq K \text{ } \varepsilon\text{-net}\}$$

Dalla definizione di spazio compatto, segue la seguente

Proposizione 2.1. *Il numero di ricoprimento di uno spazio compatto è finito*

Dimostrazione. Gli insiemi $\{B^\circ(x, \varepsilon)\}_{x \in K}$ sono un ricoprimento aperto di K . Per compattezza $\exists x_1, \dots, x_n \in K$ tale che

$$K \subseteq \bigcup_{i=1}^n B^\circ(x_i, \varepsilon) \subseteq \bigcup_{i=1}^n B(x_i, \varepsilon)$$

dunque $\{x_1, \dots, x_n\}$ formano un ε -net di K . $N(K, d, \varepsilon) \leq n$.

□

Definizione 2.3. Sia (K, d) uno spazio metrico, dato $\varepsilon > 0$. Diremo che $A \subseteq K$ è un ε -**separato** da K se

$$\forall x, y \in A \quad x \neq y \quad \Rightarrow \quad d(x, y) > \varepsilon$$

Osservazione 3. Per ogni ε , esiste un insieme ε -separato di K . Il vuoto è ε -separato.

Definizione 2.4. Sia (K, d) uno spazio metrico, dato $\varepsilon > 0$. Diremo che $A \subseteq K$ è un ε -**net** di K se

$$K \subseteq \bigcup_{x \in A} B(x, \varepsilon)$$

Definizione 2.5. Il **numero d'impacchettamento** di K (di parametro ε) è definito come

$$P(K, d, \varepsilon) = \sup \{|A| : A \subseteq K \text{ } \varepsilon\text{-separato}\}$$

2.1 Equivalenza tra i due numeri

Lemma 2.2. *Sia (K, d) metrico non vuoto. Per ogni $\varepsilon > 0$ esiste un insieme ε -separato massimale (rispetto all'inclusione).*

Dimostrazione. Se K è finito la tesi segue banalmente (tra tutti gli ε -separati si prende quello di cardinalità massima).

Se K è infinito consideriamo

$$X = \{A \subseteq K : A \text{ } \varepsilon\text{-separato}\}$$

allora (X, \subseteq) è un insieme parzialmente ordinato.

Se mostriamo che ogni catena ha un maggiorante possiamo concludere per Zorn.

Sia $Y \subseteq X$ una catena, proviamo che $\bigcup Y \in X$ e dunque è un maggiorante per la catena.

Siano $x, z \in \bigcup Y$ allora $x \in A_1, z \in A_2$. Essendo Y una catena, possiamo assumere senza perdita di generalità $A_1 \subseteq A_2$ e dunque $x, z \in A_2$. Ma A_2 è ε -separato dunque $d(x, z) > \varepsilon$. \square

Lemma 2.3. *Un ε -separato massimale è un ε -net*

Dimostrazione. Sia A un ε -separato massimale allora dobbiamo provare che

$$\forall x \in K \quad \exists x' \in A \quad d(x, x') \leq \varepsilon$$

- Se $x \in A$ allora basta prendere $x' = x$
- Se $x \notin A$ allora per massimalità $A \cup \{x\}$ non può essere ε -separato. Esistono dunque $y, z \in A \cup \{x\}$ con $d(y, z) \leq \varepsilon$.
Poichè A è ε -separato, uno tra y e z deve essere x . Supponiamo $y = x$, allora basta porre $x' = z$.

Teorema 2.4 (Equivalenza tra covering e packing number). *Per ogni spazio metrico (K, d) e per ogni $\varepsilon > 0$ vale*

$$P(k, d, 2\varepsilon) \leq N(k, d, \varepsilon) \leq P(k, d, \varepsilon)$$

Dimostrazione. Sia $A_\star \subseteq K$ un ε -separato massimale; per il lemma precedente A_\star è anche un ε -net.

Dunque vale

$$P(k, d, \varepsilon) = \sup \{|A| : A \subseteq K \text{ } \varepsilon\text{-separato}\} \geq |A_\star| \geq \inf \{|A| : A \subseteq K \text{ } \varepsilon\text{-net}\}$$

Proviamo l'altra disuguaglianza. Sia $P \subseteq K$ un 2ε -separato e $N \subseteq K$ un ε -net.

Sia $x \in P$ allora poichè N è ε -net, $\exists x_0 \in N$ tale che $d(x, x_0) \leq \varepsilon$. Pongo $f(x) = x_0$.

Ho dunque definito una funzione $f : P \rightarrow N$ (facendo ricorso all'assioma di scelta se N non è finito).

Proviamo che f è iniettiva. Siano $x, y \in P$ con $f(x) = f(y) = x_0$ allora dalla definizione di f segue che

$$d(x, x_0), d(y, x_0) \leq \varepsilon \quad \Rightarrow \quad d(x, y) \leq d(x, x_0) + d(x_0, y) \leq 2\varepsilon$$

Poichè $x, y \in P$ che è 2ε -separato, deve accadere $x = y$.

Abbiamo dunque provato che f è iniettiva e dunque $|P| \leq |N|$, si conclude per l'arbitrarietà di P e N \square

2.2 Stime per sottoinsiemi di \mathbb{R}^n

Definizione 2.6. Dati $A, B \subseteq \mathbb{R}^n$ definiamo la loro **somma di Minkowski** come

$$A + B = \{a + b : a \in A, b \in B\}$$

Proposizione 2.5. Sia $K \subseteq \mathbb{R}^n$ Lebesgue misurabile allora

$$\frac{l(K)}{l(B(0, \varepsilon))} \leq N(K, \varepsilon) \leq P(K, \varepsilon) \leq \frac{l(K + B(0, \frac{\varepsilon}{2}))}{l(B(0, \frac{\varepsilon}{2}))}$$

dove $l(A)$ indica la misura n -dimensionale di Lebesgue di A

Dimostrazione.

- Proviamo la prima disuguaglianza. Sia $A \subseteq K$ un ε -net

$$K \subseteq \bigcup_{x \in A} B(x, \varepsilon) \quad \Rightarrow \quad l(K) \leq \sum_{x \in A} l(B(x, \varepsilon)) = |A| l(B(0, \varepsilon))$$

ovvero abbiamo provato che

$$|A| \geq \frac{l(K)}{l(B(0, \varepsilon))}$$

passando all'estremo inferiore in A la tesi.

- La seconda disuguaglianza segue dal teorema di equivalenza.
- Proviamo la terza disuguaglianza. Sia $A \subseteq K$ un ε -separato. Notiamo che

$$\bigcup_{x \in A} B\left(x, \frac{\varepsilon}{2}\right) = A + B\left(0, \frac{\varepsilon}{2}\right) \subseteq K + B\left(0, \frac{\varepsilon}{2}\right)$$

Dunque usando la monotonia della misura di Lebesgue si ha

$$l\left(\bigcup_{x \in A} B\left(x, \frac{\varepsilon}{2}\right)\right) \leq l\left(K + B\left(0, \frac{\varepsilon}{2}\right)\right)$$

Ma la prima unione è disgiunta infatti essendo A un ε -separato e \mathbb{R}^d normato vale

$$\left(\forall x, y \in A \text{ distinti} \quad d(x, y) \geq \varepsilon\right) \quad \Rightarrow \quad \left(\forall x, y \in A \text{ distinti} \quad B\left(x, \frac{\varepsilon}{2}\right) \cap B\left(y, \frac{\varepsilon}{2}\right) = \emptyset\right)$$

quindi abbiamo

$$|A| l\left(B\left(0, \frac{\varepsilon}{2}\right)\right) = \sum_{x \in A} l\left(B\left(x, \frac{\varepsilon}{2}\right)\right) \leq l\left(K + B\left(0, \frac{\varepsilon}{2}\right)\right)$$

Abbiamo dunque

$$|A| \leq \frac{l(K + B(0, \frac{\varepsilon}{2}))}{l(B(0, \frac{\varepsilon}{2}))}$$

e passando al sup in A la tesi

□

Corollario 2.6. Se $l\left(K + B\left(0, \frac{\varepsilon}{2}\right)\right) < \infty$ allora i numeri di impacchettamento e di ricoprimento sono finiti. In particolare se K è limitato lo sono

Corollario 2.7. Sia $B(0, 1)$ la palla unitaria in \mathbb{R}^n allora vale

$$\left(\frac{1}{\varepsilon}\right)^n \leq N(B(0, 1), \varepsilon) \leq P(B(0, 1), \varepsilon) \leq \left(\frac{2}{\varepsilon} + 1\right)^n$$

Dimostrazione. Ricordiamo che se denotiamo con $\omega_n = l(B(0, 1))$ allora $l(B(0, r)) = r^n \omega_n$. Dalla proposizione precedente vale

$$\frac{l(B(0, 1))}{l(B(0, \varepsilon))} \leq N(B(0, 1), \varepsilon) \leq P(B(0, 1), \varepsilon) \leq \frac{l(B(0, 1) + B(0, \frac{\varepsilon}{2}))}{l(B(0, \frac{\varepsilon}{2}))}$$

Ora

$$\frac{l(B(0, 1))}{l(B(0, \varepsilon))} = \frac{\omega_n}{\varepsilon^n \omega_n}$$

Inoltre

$$B(0, 1) + B\left(0, \frac{\varepsilon}{2}\right) = B\left(0, 1 + \frac{\varepsilon}{2}\right)$$

e dunque la tesi □

Corollario 2.8. Sia S^{n-1} la sfera unitaria di \mathbb{R}^n allora vale

$$N(S^{n-1}, \varepsilon) \leq P(S^{n-1}, \varepsilon) \leq \left(\frac{2}{\varepsilon} + 1\right)^n$$

Dimostrazione. Dalla proposizione precedente si ha

$$N(S^{n-1}, \varepsilon) \leq P(S^{n-1}, \varepsilon) \leq \frac{l(S^{n-1} + B(0, \frac{\varepsilon}{2}))}{l(B(0, \frac{\varepsilon}{2}))}$$

Ma

$$S^{n-1} \subseteq B(0, 1) \Rightarrow S^{n-1} + B\left(0, \frac{\varepsilon}{2}\right) \subseteq B(0, 1) + B\left(0, \frac{\varepsilon}{2}\right) = B\left(0, 1 + \frac{\varepsilon}{2}\right)$$

Usando la monotonia della misura, la tesi. □

Osservazione 4. Nelle applicazioni ε piccolo. Se $\varepsilon \in (0, 1)$ allora $\frac{2}{\varepsilon} + 1 \leq \frac{3}{\varepsilon}$ e dunque vale

$$\left(\frac{1}{\varepsilon}\right)^n \leq l(B(0, 1)) \leq \left(\frac{3}{\varepsilon}\right)^n$$

Osservazione 5. Gli ε -net sono importanti per fare approssimazione.

Supponiamo ad esempio di avere una funzione $f : K \rightarrow \mathbb{R}$ L -lipschitz e siamo interessati a calcolare $\sup f$.

Sia A un ε -net finito di K , allora $\forall x \in K$ esiste $x_0 \in A$ con $x \in B(x_0, \varepsilon)$.

Poichè

$$|f(x) - f(x_0)| \leq Ld(x, x_0) \leq L\varepsilon$$

Otteniamo

$$\sup_{x \in K} f(x) \leq \max_{x \in A} f(x) + L\varepsilon$$

3 Teorema di Glivenko-Cantelli

Definizione 3.1. La **misura empirica** del campione aleatorio X_1, \dots, X_n è data da

$$\mathbb{P}_n = \frac{1}{n} \sum_{i=1}^n \delta_{X_i}$$

Osservazione 6. \mathbb{P}_n è una misura di probabilità su χ che è aleatoria: dipende dalla realizzazione del campione. In generale, \mathbb{P}_n è una misura atomica su χ che associa ad ogni atomo la frequenza relativa con cui appare in X_1, \dots, X_n

Definizione 3.2. Se $\chi = \mathbb{R}$ possiamo definire la **funzione di ripartizione empirica** come

$$F_n : \mathbb{R} \rightarrow [0, 1] \quad F_n(t) = \mathbb{P}_n[(-\infty, t]) = \frac{1}{n} \sum_{i=1}^n 1_{[-\infty, t]}(X_i)$$

Lemma 3.1. Sia F una funzione di ripartizione. Allora $\forall \varepsilon \in (0, 1)$ esiste una partizione

$$-\infty = t_0 < t_1 < \dots < t_{k-1} < t_k = \infty \quad t.c. \quad F(t_i^-) - F(t_{i-1}^-) \leq \varepsilon \quad \forall i = 1, \dots, k$$

dove intendiamo che $F(t_k^-) = 1$ e $F(t_0) = 0$.

Dimostrazione. Poniamo

$$t_1 = \sup \left\{ t \in \mathbb{R} \mid F(t) \leq \frac{\varepsilon}{2} \right\}$$

notiamo che tale estremo superiore esiste finito, infatti per le proprietà delle funzioni di ripartizione

$$\lim_{x \rightarrow -\infty} F(x) = 0 \quad \lim_{x \rightarrow +\infty} F(x) = 1$$

t_1 soddisfa la disuguaglianza:

$$F(t_1^-) - F(t_0) = F(t_1^-) = \lim_{t \rightarrow t_1^-} F(t) \leq \frac{\varepsilon}{2} < \varepsilon$$

ed inoltre $F(t_1) \geq \frac{\varepsilon}{2}$ infatti se per assurdo $F(t_1) < \frac{\varepsilon}{2}$ allora sfruttando la continuità a destra della F , esisterebbe un $s > t_1$ con $F(s) < \frac{\varepsilon}{2}$ contro la definizione di t_1 .

Definiamo

$$t_2 = \sup \left\{ t \in \mathbb{R} \mid F(t) \leq F(t_1) + \frac{\varepsilon}{2} \right\}$$

Se $t_2 = +\infty$ pongo $k = 2$ e concludo infatti se $t_2 = +\infty$ allora

$$\forall t \in \mathbb{R} \quad F(t) \leq F(t_1) + \frac{\varepsilon}{2}$$

passando al limite per $t \rightarrow +\infty$ ottengo

$$1 \leq F(t_1) + \frac{\varepsilon}{2} \quad \Leftrightarrow \quad 1 - F(t_1) \leq \frac{\varepsilon}{2} < \varepsilon$$

Se $t_2 < \infty$ allora sia

$$t_3 = \sup \left\{ t \in \mathbb{R} \mid F(t) \leq F(t_2) + \frac{\varepsilon}{2} \right\}$$

posso iterare la procedura definendo t_4, \dots, t_k fino a quando si avrà $t_k = +\infty$.

Il procedimento termina in un numero finito di passi infatti come abbiamo provato che $F(t_1) \geq \frac{\varepsilon}{2}$ si prova che

$$t_i < \infty \quad \Rightarrow \quad F(t_{i+1}) \geq F(t_i) + \frac{\varepsilon}{2}$$

e dunque $F(t_i) \geq \frac{i\varepsilon}{2}$ si conclude ricordando che F è limitata.

Teorema 3.2 (di Glivenko-Cantelli). *Sia $(X_n)_{n \in \mathbb{N}}$ una successione di variabili aleatorie definite sullo stesso spazio i.i.d. Se F è la funzione di ripartizione di X_1 allora quasi certamente si ha*

$$\lim_{n \rightarrow +\infty} \|F_n - F\|_\infty = 0$$

Dimostrazione. Per la legge forte dei grandi numeri, fissato $t \in \mathbb{R}$ si ha

$$\lim_{n \rightarrow +\infty} F_n(t) = F(t) \text{ q.o.}$$

infatti

$$F_n(t) = \frac{1}{n} \sum_{i=1}^n 1_{(-\infty, t]}(X_i)$$

ovvero F_n è la media campionaria di n variabili i.i.d. con media $P(X_1 \leq t) = F(t)$.

Ricordando che le funzioni di ripartizione sono continue a destra con limite a sinistra si ottiene che

$$F_n(t^-) = \frac{1}{n} \sum_{i=1}^n 1_{(-\infty, t)} \rightarrow \mathbb{E} [1_{(-\infty, t)}(X_1)] = F(t^-) \text{ q.o.}$$

Sia $t_0 < \dots < t_k$ una partizione come nel Lemma 3.1 e sia $t \in \mathbb{R}$. Poniamo i come l'unico indice che verifica $t_{i-1} \leq t < t_i$.

Usando la monotonia di F_n e di F ottengo

$$F_n(t) - F(t) \leq F_n(t_i^-) - F(t_i^-) + \varepsilon$$

$$F_n(t) - F(t) \geq F_n(t_{i-1}) - F(t_{i-1}) - \varepsilon$$

ovvero mettendo insieme le due disuguaglianze

$$|F_n(t) - F(t)| \leq \max \left\{ \max_i |F_n(t_i^-) - F(t_i^-) + \varepsilon|, \max_i |F_n(t_{i-1}) - F(t_{i-1}) - \varepsilon| \right\}$$

Per $n \rightarrow +\infty$ il membro di destra tende a ε dunque si ha

$$\forall \varepsilon \quad \limsup_{n \rightarrow +\infty} \|F_n - F\|_\infty \leq \varepsilon$$

Per l'arbitrarietà di ε si ha la tesi. □

3.1 Disuguaglianza DWK

Teorema 3.3 (Disuguaglianza DKW). *Dato un campione aleatorio $\{X_i\}_{i \in \mathbb{N}}$, sia \mathbb{F}_n la funzione di ripartizione empirica e F la funzione di ripartizione di X_1 .*

Vale

$$\mathbb{P} \left(\|\mathbb{F}_n - F\|_\infty \geq \frac{x}{\sqrt{n}} \right) \leq 2e^{-2x^2}$$

Osservazione 7. La disuguaglianza prende il nome dai 3 matematici che l'hanno dimostrata: Dvoretzky, Kiefer e Wolfowitz. Ad onore del vero, venne dimostrata con un valore della costante diverso da 2. La versione con il 2 si deve Massart.

Dalla disuguaglianza DWK segue il Teorema di Glivenko-Cantelli:

Corollario 3.4. $\forall n \in \mathbb{N}$ con probabilità 1 vale

$$\|F_n - F\| \leq \sqrt{\frac{\ln n}{n}}$$

e dunque in particolare vale il teorema di Givenko-Cantelli.

Dimostrazione. Consideriamo la successione di eventi

$$A_n = \left\{ \|F_n - F\| > \sqrt{\frac{\ln n}{n}} \right\}$$

Allora dalla disuguaglianza DKW si ha

$$\mathbb{P}(A_n) \leq 2e^{-2 \ln n} = \frac{2}{n^2}$$

e dunque

$$\sum_{n=1}^{\infty} \mathbb{P}(A_n) \leq 2 \sum_{i=1}^{\infty} \frac{1}{n^2} < \infty$$

Si conclude per Borel-Cantelli.

□

3.2 Classi di Glivenko-Cantelli

Definizione 3.3. Date μ, ν due misure su χ e supponiamo che ogni $f \in \mathfrak{F}$ sia integrabile (rispetto alle due misure) allora

$$\|\mu - \nu\|_{\mathfrak{F}} = \sup_{f \in \mathfrak{F}} |\mu(f) - \nu(f)|$$

dove

$$\mu(f) = \int_{\chi} f(x) d\mu(x)$$

Definizione 3.4. La famiglia \mathfrak{F} si dice di **Glivenko-Cantelli in senso forte** se

$$\|\mathbb{P}_n - \mathbb{P}_X\|_{\mathfrak{F}} \rightarrow 0 \text{ per } n \rightarrow +\infty \text{ q.c.}$$

La famiglia \mathfrak{F} si dice di **Glivenko-Cantelli in senso debole** se

$$\|\mathbb{P}_n - \mathbb{P}_X\|_{\mathfrak{F}} \rightarrow 0 \text{ per } n \rightarrow +\infty \text{ in probabilità}$$

Osservazione 8. Se \mathcal{F} è di Glivenko-Cantelli allora

$$\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n f(X_i) - \mathbb{E}[f(X)] \right| \rightarrow 0 \text{ q.c.} \quad (1)$$

ho dunque una famiglia di leggi forti dei grandi numeri: $\forall f \in \mathcal{F}$ ho la legge forte dei grandi numeri per la successione i.i.d $f(X_1), f(X_2), \dots$.

Siccome in (1) ho l'estremo superiore fatto su \mathcal{F} , la convergenza a 0 è uniforme: si parla in questo caso di legge uniforme dei grandi numeri.

3.3 Applicazioni di Glivenko-Cantelli

Proposizione 3.5 (Principio plug-in). *Sia*

$$\mathcal{A} = \{G : \mathbb{R} \rightarrow [0, 1] \mid G \text{ funzione di ripartizione}\}$$

dotato della norma uniforme. Sia $\mathcal{A}_0 \subseteq \mathcal{A}$ e $\gamma : \mathcal{A}_0 \rightarrow \mathbb{R}$ una funzione continua, $(X_n)_{n \in \mathbb{N}}$ variabili aleatorie i.i.d. definite sullo stesso spazio e supponiamo $\mathbb{F}_n, F \in \mathcal{A}_0$ allora quasi certamente vale

$$\gamma(\mathbb{F}_n) \rightarrow \gamma(F) \text{ per } n \rightarrow +\infty$$

Dimostrazione. Per il teorema di Glivenko-Cantelli $\|\mathbb{F}_n - F\|_\infty \rightarrow 0$ quasi certamente. Si conclude sfruttando la continuità di γ . □

Osservazione 9. La proposizione ci dice che uno stimatore ragionevole di $\gamma(F)$ (che non conosciamo, perchè non conosciamo F) è $\gamma(\mathbb{F}_n)$.

Il nome del principio deriva dal fatto che per stimare la quantità: tolgo F e metto dentro \mathbb{F}_n

Definizione 3.5. Il funzionale di Cramer-Von Mises è

$$\gamma : \mathcal{A} \rightarrow \mathbb{R} \quad \gamma(G) = \int_{\mathbb{R}} (G(t) - F_0(t))^2 dF_0(t)$$

dove $F_0(t)$ è una fissata funzione di ripartizione

Osservazione 10. $\gamma(F)$ misura quanto F si discosta da F_0

Lemma 3.6. *Il funzionale di Cramer-Von Mises è continuo*

Dimostrazione. Siano $G, \tilde{G} \in \mathcal{A}$

$$\begin{aligned} \left| \gamma(G) - \gamma(\tilde{G}) \right| &= \left| \int_{\mathbb{R}} (G(t) - F_0(t))^2 - (\tilde{G}(t) - F_0(t))^2 dF_0(t) \right| = \\ &= \left| \int_{\mathbb{R}} (G(t) - \tilde{G}(t)) (G(t) - F_0(t) + \tilde{G}(t) - F_0(t)) dF_0(t) \right| \leq \\ &\leq \int_{\mathbb{R}} |G(t) - \tilde{G}(t)| (|G(t) - F_0(t)| + |\tilde{G}(t) - F_0(t)|) dF_0(t) \end{aligned}$$

Ora l'argomento del secondo e terzo modulo è compreso in $[-1, 1]$ e dunque

$$\left| \gamma(G) - \gamma(\tilde{G}) \right| \leq 2 \|G - \tilde{G}\|_\infty$$

infatti ricordiamo che stiamo integrando rispetto a misure di probabilità. □

Esempio 3.7 (Goodness of fit test). *Vogliamo verificare l'ipotesi che la distribuzione della popolazione su \mathbb{R} sia una data \mathbb{P}_0 o quasi (equivalentemente che la funzione di ripartizione effettiva sia una data F_0 o quasi). Per fare questo posso usare il principio plug-in e stimare $\gamma(F)$ con $\gamma(\mathbb{F}_n)$*

4 Complessità di Rademacher

Definizione 4.1. Una variabile aleatoria si dice di **Rademacher** se ha distribuzione

$$f(x) = \begin{cases} \frac{1}{2} & \text{se } x = \pm 1 \\ 0 & \text{altrimenti} \end{cases}$$

Osservazione 11. A meno di allargare lo spazio di probabilità possiamo supporre che su Ω sia definito

- $\{X_i\}_{i=1}^n$ ovvero il campione aleatorio
- $\varepsilon_1, \dots, \varepsilon_n$ i.i.d. di Rademacher

ed inoltre con i vettori $(X_i)_{i=1}^n$ e $(\varepsilon_i)_{i=1}^n$ indipendenti.

Definizione 4.2. La **complessità di Rademacher** della classe \mathfrak{F} riferita al campione $\{X_i\}_{i=1}^n$ è

$$R_n(\mathfrak{F}) = \mathbb{E}_{X,\varepsilon} \left[\sup_{f \in \mathfrak{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| \right]$$

Proposizione 4.1. Valgono le seguenti proprietà per la complessità di Rademacher

(i) Date \mathcal{F} e \mathcal{G} classi di funzioni si ha

$$\mathcal{R}_n(\mathcal{F} + \mathcal{G}) \leq \mathcal{R}_n(\mathcal{F}) + \mathcal{R}_n(\mathcal{G})$$

(ii) Data \mathcal{F} classe di funzioni e $g : \chi \rightarrow \mathbb{R}$ uniformemente limitata vale

$$|\mathcal{R}_n(\mathcal{F} + g) - \mathcal{R}_n(\mathcal{F})| \leq \frac{\|g\|_\infty}{\sqrt{n}}$$

dove

$$\mathcal{F} + g = \{f + g \mid f \in \mathcal{F}\}$$

(iii) Data \mathcal{F} classe di funzioni e X v.a. a valori in χ , definiamo la classe

$$\overline{\mathcal{F}} = \{f - \mathbb{E}[f(X)] \mid f \in \mathcal{F}\}$$

Allora si ha

$$\mathcal{R}_n(\mathcal{F}) - \mathcal{R}_n(\overline{\mathcal{F}}) \leq \sup_{f \in \mathcal{F}} \frac{|f(X)|}{\sqrt{n}}$$

Dimostrazione.

(i)

$$\begin{aligned} \mathcal{R}_n(\mathcal{F} + \mathcal{G}) &= \mathbb{E}_{X,\varepsilon} \left[\sup_{\substack{f \in \mathcal{F} \\ g \in \mathcal{G}}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (f(X_i) - g(X_i)) \right| \right] \leq 1 \\ &\leq \mathbb{E}_{X,\varepsilon} \left[\sup_{\substack{f \in \mathcal{F} \\ g \in \mathcal{G}}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| + \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i g(X_i) \right| \right] \leq \\ &\leq \mathbb{E}_{X,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| + \sup_{g \in \mathcal{G}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i g(X_i) \right| \right] = \mathcal{R}_n(\mathcal{F}) + \mathcal{R}_n(\mathcal{G}) \end{aligned}$$

dove \leq_1 è la disuguaglianza triangolare

(ii) Proviamo prima che

$$\mathcal{R}_n(\mathcal{F} + g) \leq \mathcal{R}_n(\mathcal{F}) + \frac{\|g\|_\infty}{\sqrt{n}} \quad (2)$$

Se poniamo $\mathcal{G} = \{g\}$ allora vale

$$\mathcal{R}_n(\mathcal{F} + g) = \mathcal{R}_n(\mathcal{F} + \mathcal{G})$$

e dunque dal punto (i) si ha

$$\mathcal{R}_n(\mathcal{F} + \mathcal{G}) \leq \mathcal{R}_n(\mathcal{F}) + \mathcal{R}_n(\mathcal{G})$$

Ora

$$\mathcal{R}_n(\mathcal{G}) = \mathbb{E}_{X,\varepsilon} \left[\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i g(X_i) \right| \right]$$

Dalla disuguaglianza di Cauchy-Swartz si ha

$$\begin{aligned} \mathbb{E}_{X,\varepsilon} \left[\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i g(X_i) \right| \right] &\leq \mathbb{E}_{X,\varepsilon} \left[\left(\frac{1}{n} \sum_{i=1}^n \varepsilon_i g(X_i) \right)^2 \right]^{\frac{1}{2}} = \\ &= \frac{1}{n} \left(\sum_{i=1}^n \sum_{j=1}^n \mathbb{E}[\varepsilon_i \varepsilon_j g(X_i) g(X_j)] \right)^{\frac{1}{2}} = \frac{1}{n} \left(\sum_{i=1}^n \sum_{j=1}^n \mathbb{E}[\varepsilon_i \varepsilon_j] \mathbb{E}[g(X_i) g(X_j)] \right)^{\frac{1}{2}} \end{aligned}$$

dove l'ultima disuguaglianza segue dall'indipendenza dei vettori $(\varepsilon_1, \dots, \varepsilon_n)$ e $(g(X_1), \dots, g(X_n))$. Poichè

$$\mathbb{E}[\varepsilon_i \varepsilon_j] = \begin{cases} 1 & \text{se } i = j \\ 0 & \text{se } i \neq j \end{cases}$$

otteniamo

$$\mathbb{E}_{X,\varepsilon} \left[\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i g(X_i) \right| \right] \leq \frac{1}{n} \left(\sum_{i=1}^n \mathbb{E}[g(X_i)^2] \right)^{\frac{1}{2}} \leq \frac{\|g\|_\infty}{\sqrt{n}}$$

Per l'altra disuguaglianza, usiamo (2) rimpiazzando \mathcal{F} con $\mathcal{F} + g$ e g con $-g$ ottenendo

$$\mathcal{R}_n(\mathcal{F}) = \mathcal{R}_n((\mathcal{F} + g) - g) \leq \mathcal{R}_n(\mathcal{F} + g) + \frac{\| -g \|_\infty}{\sqrt{n}}$$

(iii) Definiamo una nuova classe di funzioni costanti:

$$\mathbb{E}[\mathcal{F}] = \{\mathbb{E}[f(X)] \mid f \in \mathcal{F}\}$$

Notiamo che

$$\mathcal{F} \subseteq \overline{\mathcal{F}} + \mathbb{E}[\mathcal{F}]$$

infatti

$$\forall f \in \mathcal{F} \quad f = (f - \mathbb{E}[f(X)]) + \mathbb{E}[f(X)]$$

Dal punto (i) si ha

$$\mathcal{R}_n(\mathcal{F}) \leq \mathcal{R}_n(\overline{\mathcal{F}}) + \mathcal{R}_n(\mathbb{E}[\mathcal{F}])$$

Ma

$$\begin{aligned} \mathcal{R}_n(\mathbb{E}[\mathcal{F}]) &= \mathbb{E} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \mathbb{E}[f(X)] \right| \right] = \mathbb{E} \left[\sup_{f \in \mathcal{F}} |\mathbb{E}[f(X)]| \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \right| \right] = \\ &= \sup_{f \in \mathcal{F}} |\mathbb{E}[f(X)]| \mathbb{E} \left[\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \right| \right] = \mathbb{E} \left[\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \right| \right] \sup_{f \in \mathcal{F}} |\mathbb{E}[f(X)]| \end{aligned}$$

Poichè da Cauchy-Swartz si ha

$$\mathbb{E} \left[\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \right|^2 \right] \leq \mathbb{E} \left[\left(\frac{1}{n} \sum_{i=1}^n \varepsilon_i \right)^2 \right]^{\frac{1}{2}} = \mathbb{E} \left[\frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \varepsilon_i \varepsilon_j \right] = \frac{1}{\sqrt{n}}$$

Lemma 4.2 (di simmetrizzazione). *Siano $X_1, \dots, X_n, Y_1, \dots, Y_n$ v.a. indipendenti e distribuiti come X . Siano $\varepsilon_1, \dots, \varepsilon_n$ variabili di Rademacher indipendenti tra loro e dalle X_i, Y_j . Se $f : \chi \rightarrow \mathbb{R}$ allora i vettori*

$$(f(X_1) - f(Y_1), \dots, f(X_n) - f(Y_n)) \text{ e } (\varepsilon_1(f(X_1) - f(Y_1)), \dots, \varepsilon_n(f(X_n) - f(Y_n)))$$

hanno la stessa legge.

Dimostrazione. Siano V, W i due suddetti vettori aleatori. Poichè le entrate dei due vettori sono indipendenti tra loro, basta provare che $\forall A$ boreliano vale

$$\mathbb{P}(f(X_i) - f(Y_i) \in A) = \mathbb{P}(\varepsilon_i(f(X_i) - f(Y_i)) \in A)$$

Ora

$$\begin{aligned} & \mathbb{P}(\varepsilon_i(f(X_i) - f(Y_i)) \in A) = \\ &= \frac{1}{2} \mathbb{P}(\varepsilon_i(f(X_i) - f(Y_i)) \in A \mid \varepsilon_i = 1) + \frac{1}{2} \mathbb{P}(\varepsilon_i(f(X_i) - f(Y_i)) \in A \mid \varepsilon_i = -1) = \\ &= \frac{1}{2} [\mathbb{P}(f(X_i) - f(Y_i) \in A) + \mathbb{P}(f(Y_i) - f(X_i) \in A)] \end{aligned}$$

infatti gli eventi $\{f(X_i) - f(Y_i) \in A\}$ e $\{\varepsilon_i = 1\}$ sono indipendenti (così come gli altri due). Ora poichè (X_i, Y_i) e (Y_i, X_i) hanno entrate indipendenti con medesima legge dunque

$$\mathbb{P}(f(X_i) - f(Y_i) \in A) = \mathbb{P}(f(Y_i) - f(X_i) \in A)$$

da cui la tesi. □

Teorema 4.3. *Sia $\mathcal{F} = \{f : \chi \rightarrow \mathbb{R}\}$ una classe di funzioni. Allora*

$$\frac{1}{2} \mathcal{R}_n(\overline{\mathcal{F}}) \leq \mathbb{E} [\|P_n - P_X\|_{\mathcal{F}}] \leq 2 \mathcal{R}_n(\mathcal{F})$$

Dimostrazione. Proviamo la seconda disuguaglianza. Siano (Y_1, \dots, Y_n) un vettore casuale distribuito come (X_1, \dots, X_n) e indipendente. Sia $\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)$ un vettore di Rademacher

indipendente dalle X_i e Y_j .

$$\begin{aligned}
\mathbb{E} [\|\mathbb{P}_n - P_X\|_{\mathcal{F}}] &= \mathbb{E}_X \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n f(X_i) - \mathbb{E}[f(X)] \right| \right] = \\
&= \mathbb{E}_X \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n f(X_i) - \mathbb{E}_Y[f(Y_i)] \right| \right] = \mathbb{E}_X \left[\sup_{f \in \mathcal{F}} \left| \mathbb{E}_Y \left[\frac{1}{n} \sum_{i=1}^n (f(X_i) - f(Y_i)) \right] \right| \right] \leq \\
&\leq \mathbb{E}_X \left[\sup_{f \in \mathcal{F}} \mathbb{E}_Y \left[\left| \frac{1}{n} \sum_{i=1}^n (f(X_i) - f(Y_i)) \right| \right] \right] \leq_1 \mathbb{E}_{X,Y} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n f(X_i) - f(Y_i) \right| \right] =_2 \\
&= \mathbb{E}_{X,Y,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (f(X_i) - f(Y_i)) \right| \right] \leq_3 \mathbb{E}_{X,Y,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left(\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| + \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(Y_i) \right| \right) \right] \leq \\
&\leq \mathbb{E}_{X,Y,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| + \sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(Y_i) \right| \right] = \\
&= \mathbb{E}_{X,Y,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| \right] + \mathbb{E}_{X,Y,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(Y_i) \right| \right] = 2\mathcal{R}_n(\mathcal{F})
\end{aligned}$$

dove

- \leq_1 è il Lemma 15.1,
- $=_2$ è il lemma di simmetrizzazione e
- \leq_3 è la disuguaglianza triangolare

Proviamo la prima disuguaglianza

$$\begin{aligned}
\mathcal{R}_n(\overline{\mathcal{F}}) &= \mathbb{E}_{X,\varepsilon} \left[\sup_{f \in \overline{\mathcal{F}}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| \right] = E_{X,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (f(X_i) - \mathbb{E}[f(X)]) \right| \right] = \\
&= E_{X,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (f(X_i) - \mathbb{E}[f(Y_i)]) \right| \right] = E_{X,\varepsilon} \left[\sup_{f \in \mathcal{F}} \mathbb{E}_Y \left[\left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (f(X_i) - f(Y_i)) \right| \right] \right] \\
&\leq_1 \mathbb{E}_{X,Y,\varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (f(X_i) - f(Y_i)) \right| \right] =_2 \mathbb{E}_{X,Y} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n f(X_i) - f(Y_i) \right| \right] \leq_3 \\
&\leq_3 \mathbb{E}_{X,Y} \left[\sup_{f \in \mathcal{F}} \left\{ \left| \frac{1}{n} \sum_{i=1}^n f(X_i) - \mathbb{E}[f(X_i)] \right| + \left| \frac{1}{n} \sum_{i=1}^n f(Y_i) - \mathbb{E}[f(Y_i)] \right| \right\} \right] \leq \\
&\leq \mathbb{E}_{X,Y} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n f(X_i) - \mathbb{E}[f(X_i)] \right| \right] + \mathbb{E}_{X,Y} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n f(Y_i) - \mathbb{E}[f(Y_i)] \right| \right] = \\
&= 2\mathbb{E}_X [\|\mathbb{P}_n - P_X\|_{\mathcal{F}}]
\end{aligned}$$

dove

- \leq_1 è il Lemma 15.1,
- $=_2$ è il lemma di simmetrizzazione
- \leq_3 si ottiene sommando e sottraendo $\mathbb{E}[f(X_i)] = \mathbb{E}[f(Y_i)]$ e applicando la disuguaglianza triangolare

□

Osservazione 12. Usando il punto (iii) della proposizione della scorsa lezione, otteniamo

$$\frac{1}{2}\mathcal{R}_n(\mathcal{F}) - \sup_{f \in \mathcal{F}} \frac{|\mathbb{E}[f(X)]|}{2\sqrt{n}} \leq \mathbb{E}[\|\mathbb{P}_n - P_X\|_{\mathcal{F}}] \leq 2\mathcal{R}_n(\mathcal{F})$$

Inoltre, nelle applicazioni la classe \mathcal{F} è formata da funzioni limitate uniformemente da una costante b e dunque si ha

$$\frac{1}{2}\mathcal{R}_n(\mathcal{F}) - \frac{b}{2\sqrt{n}} \leq \mathbb{E}[\|\mathbb{P}_n - P_X\|_{\mathcal{F}}] \leq 2\mathcal{R}_n(\mathcal{F})$$

Definizione 4.3. Una funzione $g : \chi^n \rightarrow \mathbb{R}$ si dice che soddisfa la **proprietà delle differenze limitate** con parametri (l_1, \dots, l_n) se

$$\forall k \in [n] \quad \forall x, x' \in \chi^n \quad (x_i = x'_i \ \forall i \neq k \quad \Rightarrow \quad |g(x) - g(x')| \leq l_k)$$

Teorema 4.4. Sia $g : \chi^n \rightarrow \mathbb{R}$ una funzione misurabile che soddisfa la proprietà delle differenza finite con parametro (l_1, \dots, l_n) . Se (X_1, \dots, X_n) è un vettore aleatorio su χ^n con coordinate indipendenti vale

$$\mathbb{P}[|g(X_1, \dots, X_n) - \mathbb{E}[g(X_1, \dots, X_n)]| > t] \leq \exp\left(-\frac{2t^2}{\sum l_k^2}\right)$$

Teorema 4.5. Sia $\mathcal{F} = \{f : \mathbb{R} \rightarrow \mathbb{R} \mid \|f\|_{\infty} \leq b\}$ e $\delta > 0$.

Con probabilità di $1 - 2 \exp\left(-\frac{\delta^2 n}{2b^2}\right)$ vale

$$\frac{1}{2}\mathcal{R}_n(\overline{\mathcal{F}}) - \delta \leq \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \leq 2\mathcal{R}_n(\mathcal{F}) + \delta$$

Dimostrazione. Data $f \in \mathcal{F}$, pongo $\overline{f} = f - \mathbb{E}[f(X)]$. Definiamo la funzione

$$g : \chi^n \rightarrow \mathbb{R} \quad g(x_1, \dots, x_n) = \sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_j \overline{f}(x_j) \right|$$

Proviamo che g soddisfa la proprietà delle differenza finite con parametro $\frac{2b}{n}$. Poichè g è invariante per permutazione delle coordinate, basta provare che

$$|g(x_1, \dots, x_n) - g(y_1, \dots, y_n)| \leq \frac{2b}{n} \quad \text{se } x_j = y_j \quad \forall j \neq 1$$

Fissata $f \in \mathcal{F}$ ho

$$\begin{aligned} \left| \frac{1}{n} \sum_{i=1}^n \overline{f}(x_i) \right| - \sup_{h \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \overline{h}(y_i) \right| &\leq \left| \frac{1}{n} \sum_{i=1}^n \overline{f}(x_i) \right| - \left| \frac{1}{n} \sum_{i=1}^n \overline{f}(y_i) \right| \leq \\ &\leq \left| \frac{1}{n} \sum_{i=1}^n \overline{f}(x_i) - \frac{1}{n} \sum_{i=1}^n \overline{f}(y_i) \right| = \left| \frac{1}{n} (\overline{f}(x_1) - \overline{f}(y_1)) \right| = \\ &= \left| \frac{1}{n} (f(x_1) - f(y_1)) \right| \leq \frac{1}{n} (|f(x_1)| + |f(y_1)|) \leq \frac{2b}{n} \end{aligned}$$

Dal Teorema 4.4 otteniamo $\forall \delta > 0$ vale

$$\mathbb{P}(\|\mathbb{P}_n - P_X\|_{\mathcal{F}} - \mathbb{E}[\|\mathbb{P}_n - P_X\|_{\mathcal{F}}] \geq \delta) \leq 2 \exp\left(-\frac{n\delta^2}{2b^2}\right)$$

dunque con probabilità maggiore di $1 - 2 \exp\left(-\frac{n\delta^2}{2b^2}\right)$ ho

$$\mathbb{E}[\|\mathbb{P}_n - P_X\|_{\mathcal{F}} - \delta \leq \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \leq \mathbb{E}[\|\mathbb{P}_n - P_X\|_{\mathcal{F}}] + \delta$$

La tesi segue applicando le stime date dal Teorema 4.3 □

Osservazione 13. Il teorema ci dice che la stima ottenuta in media vale con una probabilità alta (a meno di δ) puntualmente.

Corollario 4.6. *Sia \mathcal{F} una classe di funzioni uniformemente limitate da b*

$$\mathcal{F} \text{ è di Glivenko-Cantelli in senso forte rispetto a } P_X \iff \lim_{n \rightarrow +\infty} \mathcal{R}_n(\mathcal{F}) = 0$$

Dimostrazione. \Leftarrow Supponiamo che $\mathcal{R}_n(\mathcal{F}) \rightarrow 0$, fissato $\delta > 0$ consideriamo la successione di eventi

$$A_n = \{\|\mathbb{P}_n - P_X\|_{\mathcal{F}} > 2\mathcal{R}_n(\mathcal{F}) + \delta\}$$

Allora dal Teorema 4.5 si ha $\mathbb{P}(A_n) \leq 2 \exp\left(-\frac{n\delta^2}{2b^2}\right)$ e dunque $\sum \mathbb{P}(A_n) < \infty$. Per il lemma di Borel-Cantelli otteniamo $\mathbb{P}(A_n \text{ i.o.}) = 0$ quindi

$$\forall \delta > 0 \text{ q.c. } \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \leq 2\mathcal{R}_n(\mathcal{F}) + \delta \text{ definitivamente in } n$$

equivalentemente

$$\forall k \in \mathbb{N} \text{ q.c. } \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \leq 2\mathcal{R}_n(\mathcal{F}) + \frac{1}{k} \text{ definitivamente in } n$$

poichè l'unione numerabile di eventi con probabilità 1 ha probabilità 1 si ha

$$\text{q.c. } \forall k \in \mathbb{N} \quad \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \leq 2\mathcal{R}_n(\mathcal{F}) + \frac{1}{k} \text{ definitivamente in } n$$

e dunque

$$\text{q.c. } \forall k \in \mathbb{N} \quad \limsup_{n \rightarrow +\infty} \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \leq \frac{1}{k}$$

Per l'arbitrarietà di k , la tesi.

\Rightarrow Supponiamo per assurdo che $\mathcal{R}_n(\mathcal{F}) \not\rightarrow 0$ e dunque $\limsup \mathcal{R}_n(\mathcal{F}) > 0$.

Dato $\delta > 0$ definiamo la successione di eventi

$$B_n = \left\{ \frac{1}{n} \mathcal{R}_n(\mathcal{F}) - \frac{b}{2\sqrt{n}} > \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \right\}$$

Per il Teorema 4.5, $\mathbb{P}(B_n) \leq 2 \exp\left(-\frac{n\delta^2}{2b^2}\right)$ e dunque $\sum \mathbb{P}(B_n) < \infty$.

Per il lemma di Borel-Cantelli otteniamo $\mathbb{P}(B_n \text{ i.o.}) = 0$ quindi

$$\forall \delta \text{ q.c. } \frac{1}{2} \mathcal{R}_n(\mathcal{F}) - \frac{b}{2\sqrt{n}} \leq \|\mathbb{P}_n - P_X\|_{\mathcal{F}} \text{ definitivamente in } n$$

Ragionando come fatto nella dimostrazione dell'altra implicazione otteniamo

$$\text{q.c. } \limsup_{n \rightarrow +\infty} \mathcal{R}_n(\mathcal{F}) - \frac{1}{k} \leq \limsup_{n \rightarrow +\infty} \|\mathbb{P}_n - P_X\|_{\mathcal{F}}$$

Per l'arbitrarietà di k otteniamo

$$\text{q.c. } \limsup_{n \rightarrow +\infty} \mathcal{R}_n(\mathcal{F}) \leq \limsup_{n \rightarrow +\infty} \|\mathbb{P}_n - P_X\|_{\mathcal{F}}$$

Poichè il termine di sinistra è strettamente positivo, lo è anche quello di destra e contro l'ipotesi che \mathcal{F} sia di Glivenko-Cantelli □

4.1 Discriminante polinomiale

D'ora in avanti useremo le due seguenti notazioni:

- La n -upla (x_1, \dots, x_n) con x_1^n .
- Se \mathcal{F} è una classe di funzioni su χ definiamo

$$\mathcal{F}(x_1^n) = \{(f(x_1), \dots, f(x_n)) \mid f \in \mathcal{F}\}$$

Definizione 4.4. Una classe di funzioni \mathcal{F} su χ ha **discriminante polinomiale** di ordine ν se

$$\forall n \geq 1 \quad \forall x_1^n \in \chi^n \quad |\mathcal{F}(x_1^n)| \leq (n+1)^\nu$$

Lemma 4.7. Sia \mathcal{F} una classe di funzioni a discriminante polinomiale di ordine $\nu \geq 1$. Allora $\forall n$ e $\forall x_1^n \in \chi^n$ vale

$$\mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(x_i) \right| \right] \leq 2D(x_1^n) \sqrt{\frac{\nu \ln(n+1)}{n}}$$

dove

$$D(x_1^n) = \sup_{f \in \mathcal{F}} \sqrt{\frac{\sum_{i=1}^n f(x_i)^2}{n}}$$

Dimostrazione. Fissati x_1, \dots, x_n e sia $\lambda > 0$. Applicando la disuguaglianza di Jensen con $\varphi(t) = e^{\lambda t}$ otteniamo

$$\begin{aligned} & \exp \left(\lambda \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(x_i) \right| \right] \right) \leq \mathbb{E}_\varepsilon \left[\exp \left(\lambda \sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(x_i) \right| \right) \right] = \\ & = \mathbb{E}_\varepsilon \left[\exp \left(\lambda \sup_{a \in \mathcal{F}(x_1^n)} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i a_i \right| \right) \right] \leq E_\varepsilon \left[\sup_{a \in \mathcal{F}(x_1^n)} \exp \left(\lambda \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i a_i \right| \right) \right] \leq \\ & \leq \mathbb{E}_\varepsilon \left[\sup_{a \in \mathcal{F}(x_1^n)} \left(e^{\frac{\lambda}{n} \sum \varepsilon_i a_i} + e^{-\frac{\lambda}{n} \sum \varepsilon_i a_i} \right) \right] \leq E_\varepsilon \left[\sum_{a \in \mathcal{F}(x_1^n)} e^{\frac{\lambda}{n} \sum \varepsilon_i a_i} + e^{-\frac{\lambda}{n} \sum \varepsilon_i a_i} \right] = \\ & = \sum_{a \in \mathcal{F}(x_1^n)} E_\varepsilon \left[e^{\frac{\lambda}{n} \sum \varepsilon_i a_i} + e^{-\frac{\lambda}{n} \sum \varepsilon_i a_i} \right] =_1 2 \sum_{a \in \mathcal{F}(x_1^n)} E_\varepsilon \left[e^{\frac{\lambda}{n} \sum \varepsilon_i a_i} \right] =_2 \sum_{a \in \mathcal{F}(x_1^n)} \prod_{i=1}^n E_\varepsilon \left[e^{\frac{\lambda}{n} \varepsilon_i a_i} \right] = \\ & = 2 \sum_{a \in \mathcal{F}(x_1^n)} \prod_{i=1}^n \frac{e^{\frac{\lambda}{n} a_i} + e^{-\frac{\lambda}{n} a_i}}{2} \leq_1 2 \sum_{a \in \mathcal{F}(x_1^n)} \prod_{i=1}^n \exp \left(\frac{\lambda^2 a_i^2}{2n^2} \right) = 2 \sum_{a \in \mathcal{F}(x_1^n)} \exp \left(\frac{\lambda^2}{2n^2} \|a\|^2 \right) \leq_2 \\ & \leq_2 2 |\mathcal{F}(x_1^n)| \exp \left(\frac{\lambda^2}{2n^2} r^2 \right) \leq_3 2(n+1)^\mu \exp \left(\frac{\lambda^2}{2n^2} r^2 \right) \end{aligned}$$

dove

- $=_1$ deriva dal fatto che ε_i e $-\varepsilon_i$ hanno la stessa distribuzione
- $=_2$ deriva dal fatto che $\varepsilon_1, \dots, \varepsilon_n$ sono tra loro indipendenti
- \leq_1 si ottiene dal seguente sviluppo in serie di Taylor

$$\frac{e^x + e^{-x}}{2} = \sum_{k=0}^{\infty} \frac{x^{2k}}{(2k)!} \leq \sum_{k=0}^{\infty} x^2 k 2^k k! = e^{\frac{x^2}{2}}$$

- \leq_2 abbiamo posto

$$r = \max_{a \in \mathcal{F}(x_1^n)} \|a\|$$

- \leq_3 \mathcal{F} ha discriminante polinomiale di ordine ν

Abbiamo dunque provato che

$$\exp \left(\lambda \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(x_i) \right| \right] \right) \leq 2(n+1)^\mu \exp \left(\frac{\lambda^2}{2n^2} r^2 \right) \quad (3)$$

Applicando il logaritmo e dividendo per λ entrambi i termini di (3) si ha

$$\mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(x_i) \right| \right] \leq \frac{1}{\lambda} \ln(2(n+1)^\mu) + \frac{r^2}{2n^2} \lambda = \frac{A}{\lambda} + B\lambda \quad (4)$$

Poichè λ è un parametro libero lo scelgo affinché il membro di sinistra sia minimo.

Una semplice verifica mostra che il minimo si ha per $\lambda = 2\sqrt{AB}$, riscrivendo (4) per tale valore otteniamo

$$\mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(x_i) \right| \right] \leq_1 D(x_1^n) \sqrt{\frac{2 \ln(2(n+1)^\mu)}{n}} \leq_2 2 \sqrt{\frac{\nu \ln(n+1)}{n}}$$

dove

- \leq_1 abbiamo usato che

$$r = \max_{a \in \mathcal{F}(x_1^n)} \|a\| = \sup_{f \in \mathcal{F}} \sqrt{\sum_{i=1}^n f(x_i)} \Rightarrow \frac{r}{\sqrt{n}} = D(x_1^n)$$

- \leq_2 poichè $\nu \geq 1$ otteniamo $\ln 2 \leq \ln((n+1)^\nu)$ e dunque

$$\ln(2(n+1)^\nu) = \ln 2 + \ln((n+1)^\nu) \leq 2 \ln((n+1)^\nu) = 2\nu \ln(n+1)$$

□

Corollario 4.8. *Sia \mathcal{F} una classe di funzioni su χ uniformemente limitata da b con discriminante polinomiale di ordine ν . Allora*

$$\mathcal{R}_n(\mathcal{F}) \leq 4b \sqrt{\frac{\nu \ln(n+1)}{n}}$$

Dimostrazione. Sotto la condizione di uniforme limitatezza ho $D(x_1^n) \leq b$.

Rimpiazzando nel lemma x_1^n con (X_1, \dots, X_n) e calcolando il valore atteso rispetto a X ad entrambi i membri ottengo la tesi (il membro di destra non è aleatorio).

□

Corollario 4.9. *Se \mathcal{F} è una classe di funzioni uniformemente limitate da b con discriminante polinomiale di ordine ν allora $\forall \delta > 0$ si ha*

$$\mathbb{P} \left(\|\mathbb{P}_n - P_X\|_{\mathcal{F}} < \delta + 2b \sqrt{\frac{\nu \ln(n+1)}{n}} \right) \geq 1 - 2 \exp \left(-\frac{n\delta^2}{2b^2} \right)$$

ed inoltre \mathcal{F} è di Glivenko-Cantelli in senso forte.

Dimostrazione. La tesi segue dal Corollario 4.8 e dal Teorema 4.5.

“

5 Dimensione VC

Definizione 5.1. Sia χ un insieme

$$\mathcal{B}(\chi) = \{f : \chi \rightarrow \{0, 1\}\} = \{\text{funzioni booleane su } \chi\}$$

Osservazione 14. Esiste una bigezione tra $\mathcal{P}(\chi)$ e $\mathcal{B}(\chi)$ definita mandando il sottoinsieme S nella sua funzione caratteristica.

Definizione 5.2. Sia $\mathcal{F} \subseteq \mathcal{B}(\chi)$. Diremo che $\Lambda \subseteq \chi$ è **shattered** (**frantumato**) da \mathcal{F} se ogni funzione $g \in \mathcal{B}(\Lambda)$ è la restrizione a Λ di una funzione $f \in \mathcal{F}$

Osservazione 15. Λ è frantumato da \mathcal{F} se

$$\mathcal{B}(\Lambda) = \{f|_{\Lambda} \mid f \in \mathcal{F}\} =: \mathcal{F}|_{\Lambda}$$

Osservazione 16. Sia $\Lambda = \{x_1, \dots, x_n\}$ finito.

$$\Lambda \text{ è frantumato da } \mathcal{F} \iff |\mathcal{F}(x_1^n)| = 2^n$$

Definizione 5.3. Dato $\mathcal{F} \subseteq \mathcal{B}(\chi)$ definiamola sua **dimensione VC** come la massima cardinalità di $\Lambda \subseteq \chi$ frantumato da \mathcal{F} . Se tale massimo non esiste diremo che la sua dimensione VC è $+\infty$

Lemma 5.1. Se $d = VC(\mathcal{F})$ allora

$$|\mathcal{F}| \geq 2^d$$

Dimostrazione. Sia $\Lambda \subseteq \chi$ l'insieme frantumato che realizza il massimo. Essendo Λ frantumato la mappa

$$\psi : \mathcal{F} \rightarrow \mathcal{B}(\Lambda) \quad \psi(f) = f|_{\Lambda}$$

è suriettiva e dunque $2^d = |\mathcal{B}(\Lambda)| \leq |\mathcal{F}|$ □

Lemma 5.2 (di Sauer–Shelah). Sia $\mathcal{F} \subseteq \mathcal{B}(\chi)$. Se $|\chi| = n$ e $d = VC(\mathcal{F})$ vale

$$|\mathcal{F}| \leq \sum_{k=0}^d \binom{n}{k} \leq (n+1)^d$$

Dimostrazione. Proviamo solo la seconda disuguaglianza (non è originariamente parte del lemma).

Dalla formula del binomio di Newton:

$$(n+1)^d = \sum_{k=0}^d \binom{d}{k} n^k$$

Ma

$$\binom{d}{k} n^k = \frac{d(d-1)\cdots(d-k+1)}{k!} n^k \geq \frac{n^k}{k!} \geq \frac{n(n-1)\cdots(n-k+1)}{k!} = \binom{n}{k}$$

Proposizione 5.3. Sia $\mathcal{F} \subseteq \mathcal{B}(\chi)$ con $d = VC(\mathcal{F}) < \infty$. Allora \mathcal{F} ha discriminante polinomiale di ordine d

Dimostrazione. Fissiamo una n -upla $x_1^n \in \chi^n$ e supponiamo che sia formata da elementi distinti. Siccome gli elementi sono distinti c'è una biezione naturale tra $\mathcal{F}(x_1^n)$ e $f_{|\Lambda}$ con $\Lambda = \{x_1, \dots, x_n\}$. Dunque

$$|\mathcal{F}(x_1^n)| = |\mathcal{F}_{|\Lambda}| \leq (n+1)^{VC(\mathcal{F}_{|\Lambda})}$$

dove l'ultima disuguaglianza è il lemma di Sauer–Shelah.

Per concludere proviamo che $\forall \Lambda \subseteq \chi$ si ha $VC(\mathcal{F}_{|\Lambda}) \leq VC(\mathcal{F})$.

Supponiamo per assurdo che $VC(\mathcal{F}_{|\Lambda}) > VC(\mathcal{F})$ allora deve esistere $A \subseteq \Lambda$ frantumato da $\mathcal{F}_{|\Lambda}$ con $|A| > VC(\mathcal{F})$ quindi

$$\mathcal{B}(A) = \{g_{|A} \mid g \in \mathcal{F}_{|\Lambda}\} \Rightarrow \mathcal{B}(A) = \{g_{|A} \mid g \in \mathcal{F}\}$$

infatti se $g \in \mathcal{F}_{|\Lambda}$ allora $g = f_{|A}$ con $f \in \mathcal{F}$.

Abbiamo provato che A è frantumato da \mathcal{F} il che è assurdo.

Se x_1, \dots, x_n non sono distinti, sia y_1, \dots, y_k la sotto-upla estratta massimale che contiene elementi distinti. Allora esiste una biezione naturale tra $\mathcal{F}(x_1^n)$ e $\mathcal{F}(y_1^k)$ quindi

$$|\mathcal{F}(x_1^n)| = |\mathcal{F}(y_1^k)| \leq (k+1)^{VC(\mathcal{F})} \leq (n+1)^{VC(\mathcal{F})}$$

dove la prima disuguaglianza deriva dal caso precedente. □

Osservazione 17. La proposizione non garantisce l'ottimalità dell'ordine.

Come conseguenza immediata della Proposizione 5.3 e del Corollario 4.8 otteniamo

Proposizione 5.4. *Sia $\mathcal{F} \subseteq \mathcal{B}(\chi)$ con $VC(\mathcal{F}) < \infty$. Allora*

$$R_n(\mathcal{F}) \leq 2\sqrt{\frac{VC(\mathcal{F}) \ln(n+1)}{n}}$$

Dimostrazione. Infatti le funzioni in f sono booleane e quindi limitate uniformemente da 1 □

In realtà vale una stima molto più forte (che non dimostremo)

Teorema 5.5.

$$R_n(\mathcal{F}) \leq 2C\sqrt{\frac{VC(\mathcal{F})}{n}}$$

Osservazione 18. $\mathcal{R}_n(\mathcal{F})$ è un oggetto probabilistico molto complesso: è un valore atteso della soluzione di un problema di ottimizzazione random. Il membro destro della disuguaglianza precedente non ha nulla di probabilistico e in molti casi si calcola molto facilmente.

6 Statistical Learning

L'obiettivo della statistical learning è quello di stimare, guardando i dati, una funzione $T : \chi \rightarrow \mathbb{R}$ detta **funzione target**. Ovvero se X_1, \dots, X_n è un campione casuale in χ con distribuzione P_X , voglio approssimare T tramite l'osservazione del **training data**: $(X_1, T(X_1)), \dots, (X_n, T(X_n))$.

Osservazione 19. Spesso nelle applicazioni, $T \in \mathcal{B}(\chi)$

Esempio 6.1. Supponiamo che siano sufficienti d misure per determinare se una persona ha o meno il diabete, ovvero, supporremo che esista una funzione

$$T : \mathbb{R}^d \rightarrow \{0, 1\} \quad T(k_1, \dots, k_d) = 1 \quad \Leftrightarrow \quad \text{la persona con dati}(k_1, \dots, k_d) \text{ è diabetica}$$

Nella pratica, non conoscendo T , vogliamo trovare una sua rappresentazione approssimata. Per farlo fisso una classe di funzioni \mathcal{F} e cercherò in \mathcal{F} la mia approssimazione. In tal caso \mathcal{F} prende il nome di **spazio ipotesi**.

Definizione 6.1. Il **rischio** associato a $f \in \mathcal{F}$ è definito come

$$R(f) = \mathbb{E} [(f(X) - T(X))^2]$$

e denotiamo come

$$f^* = \underset{f \in \mathcal{F}}{\operatorname{argmin}} R(f)$$

dove abbiamo assunto che la mappa che manda f nel suo rischio abbia un punto di minimo.

Definizione 6.2. Il **rischio empirico** di $f \in \mathcal{F}$ è definito da

$$R_n(f) = \frac{1}{n} \sum_{i=1}^n (f(X_i) - T(X_i))^2$$

e denotiamo con

$$f_n^* = \arg \min_{f \in \mathcal{F}} R_n(f)$$

Osservazione 20. Notiamo che essendo la funzione T sconosciuta non è possibile calcolare f^* e tantomeno $R(f^*)$ mentre, avendo a disposizione il training set, posso calcolare esplicitamente la mappa che associa a f il suo rischio empirico e minimizzandola (assumendo che abbia minimo) calcolare f_n^* .

Da quanto appena detto, segue che la domanda opportuna da farsi non è stimare o calcolare l'errore di f_n^* ma piuttosto occorre capire quanto errore si aggiunge rispetto all'errore minimo $R(f^*)$ scegliendo come "predictor" f_n^*

Definizione 6.3. Il **rischio in eccesso** è dato da $R(f_n^*) - R(f^*)$

Proposizione 6.2. Supponiamo che $\mathcal{F} \subseteq \mathcal{B}(\chi)$ e $T \in \mathcal{B}(\chi)$ allora vale

$$0 \leq R(f_n^*) - R(f^*) \leq 2 \sup_{f \in \mathcal{F}} |R_n(f) - R(f)| = 2 \|\mathbb{P}_n - P_X\|_{\mathcal{L}}$$

dove

$$\mathcal{L} = \{(f - T)^2 \mid f \in \mathcal{F}\} = \{1_{f \neq T} \mid f \in \mathcal{F}\}$$

Dimostrazione. Chiamiamo

$$\varepsilon = \sup_{f \in \mathcal{F}} |R_n(f) - R(f)|$$

Dalla definizione di ε e usando che $f_n^* \in \mathcal{F}$ otteniamo

$$|R_n(f_n^*) - R(f_n^*)| \leq \varepsilon \quad \Rightarrow \quad R(f_n^*) \leq R_n(f_n^*) + \varepsilon$$

Dalla definizione di ε e usando che $f^* \in \mathcal{F}$ otteniamo

$$|R_n(f^*) - R(f^*)| \leq \varepsilon \quad \Rightarrow \quad R_n(f^*) \leq R(f^*) + \varepsilon$$

dunque combinando le due disuguaglianze e usando la definizione di f_n^* come punto di minimo della funzione $R_n(\cdot)$ si ha

$$R(f_n^*) \leq R_n(f_n^*) + \varepsilon \leq R_n(f^*) + \varepsilon \leq R(f^*) + 2\varepsilon$$

Notiamo inoltre che

$$R(f^*) = \min_{f \in \mathcal{F}} R(f) \leq R(f_n^*) \quad \Rightarrow \quad R(f_n^*) - R(f^*) \geq 0$$

Proviamo ora l'ultima uguaglianza della tesi

$$\begin{aligned} \varepsilon &= \sup_{f \in \mathcal{F}} |R_n(f) - R(f)| = \sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n (f(X_i) - T(x_i))^2 - \mathbb{E} [(f(X) - T(X))^2] \right| = \\ &= \sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n (f - T)^2(X_i) - \mathbb{E} [(f - T)^2(X)] \right| = \sup_{h \in \mathcal{L}} \left| \frac{1}{n} \sum_{i=1}^n h(X_i) - \mathbb{E}[h(X)] \right| \end{aligned}$$

Ma l'ultimo termine è proprio $\|\mathbb{P}_n - P_X\|_{\mathcal{L}}$

□

Per stimare il rischio in eccesso possiamo stimare la complessità della classe \mathcal{L} con quella di \mathcal{F} utilizzando la

Proposizione 6.3. *Sia \mathcal{L} come nella Proposizione 6.2 allora*

$$\mathcal{R}_n(\mathcal{L}) \leq \mathcal{R}(\mathcal{F}) + \frac{1}{\sqrt{n}}$$

Dimostrazione. Data una funzione $g \in \mathcal{B}(\chi)$, definiamo

$$\tilde{g} : \chi \rightarrow \{-1, 1\} \quad \tilde{g}(x) = \begin{cases} 1 & \text{se } g(x) = 1 \\ -1 & \text{se } g(x) = 0 \end{cases}$$

Allora

$$\mathcal{R}_n(\mathcal{L}) = \mathbb{E}_{X, \varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (f(X_i) - T(x_i))^2 \right| \right]$$

Ora

$$(f(X_i) - T(x_i))^2 = 1_{f(X_i) \neq T(x_i)} = 1_{\tilde{f}(X_i) \neq \tilde{T}(X_i)} = \frac{1 - \tilde{f}(X_i)\tilde{T}(X_i)}{2}$$

e dunque

$$\mathcal{R}_n(\mathcal{L}) = \frac{1}{2} \mathbb{E}_{X, \varepsilon} \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (1 - \tilde{f}(X_i)\tilde{T}(X_i)) \right| \right]$$

Ora

$$\begin{aligned} Z(X_1, \dots, X_n) &= \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (1 - \tilde{f}(X_i) \tilde{T}(X_i)) \right| \right] \leq \\ &\leq \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \right| \right] + \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \tilde{f}(X_i) \tilde{T}(X_i) \right| \right] \end{aligned}$$

Ma (vedi Proposizione 4.3 (iii))

$$\mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \right| \right] \leq \frac{1}{\sqrt{n}}$$

inoltre, $\tilde{T}(X_1), \dots, \tilde{T}(X_n)$ sono numeri fissati in $\{-1, 1\}$ e dunque i vettori $(\varepsilon_i \tilde{T}(X_i))_{i=1}^n$ e $(\varepsilon_i)_{i=1}^n$ sono ugualmente distribuiti. Quindi

$$\begin{aligned} Z(X_1, \dots, X_n) &\leq \frac{1}{\sqrt{n}} + \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \tilde{f}(X_i) \right| \right] =_1 \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (2f(X_i) - 1) \right| \right] \leq \\ &\leq 2\mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| \right] + \mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i \right| \right] \leq \frac{1}{\sqrt{n}} + 2\mathbb{E}_\varepsilon \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(X_i) \right| \right] \end{aligned}$$

Prendendo il valore atteso rispetto a (X_1, \dots, X_n) otteniamo la tesi. □

Corollario 6.4. *Supponiamo che $\mathcal{F} \subseteq \mathcal{B}(X)$ abbia dimensione VC finita e $T \in \mathcal{B}(X)$ allora*

$$\mathbb{E} [R(f_n^*) - R(f^*)] \leq 8\sqrt{\frac{VC(\mathcal{F}) \ln(n+1)}{n}} + \frac{2}{\sqrt{n}}$$

Dimostrazione. Usando la Proposizione 6.2 e il Teorema 4.3 otteniamo ha

$$\mathbb{E} [R(f_n^*) - R(f^*)] \leq \mathbb{E} [\|\mathbb{P}_n - P_X\|]_{\mathcal{L}} \leq 2\mathcal{R}(\mathcal{L})$$

Dalla Proposizione 6.3 si ha

$$\mathcal{R}_n(\mathcal{L}) \leq \mathcal{R}(\mathcal{F}) + \frac{1}{\sqrt{n}}$$

e stimando la complessità di Rademacher con la dimensione VC (Proposizione 5.4) otteniamo la tesi □

In realtà abbiamo un teorema più forte che dice

Teorema 6.5 (Rischio in eccesso via dimensione VC). *Supponiamo che la classe \mathcal{F} abbia $1 \leq VC(\mathcal{F}) < \infty$. Allora*

$$\mathbb{E} [R(f_n^*) - R(f^*)] \leq C\sqrt{\frac{VC(\mathcal{F})}{n}}$$

dove C è una costante assoluta calcolabile

7 Variabili aleatorie gaussiane e subgaussiane

7.1 Variabili aleatorie normali

Ricordiamo alcune proprietà sulle variabili aleatorie normali senza fornire dimostrazioni (se non alcuni cenni)

Proposizione 7.1. *Se $X \sim \mathcal{N}(0, 1)$ allora per ogni $t \geq 0$ vale*

$$\mathbb{P}(X \geq t) \leq \frac{1}{t\sqrt{2\pi}} e^{-\frac{t^2}{2}}$$

Definizione 7.1. La funzione Γ è definita come

$$\Gamma : (0, +\infty) \rightarrow (0, +\infty) \quad \Gamma(z) = \int_0^{+\infty} x^{z-1} e^{-x} dx$$

Proposizione 7.2. *Sia $X \sim \mathcal{N}(0, 1)$ allora valgono i seguenti fatti*

(i) *Per ogni $t \geq 0$ vale*

$$\mathbb{P}(|X| > t) \leq 2e^{-\frac{t^2}{2}}$$

(ii) *Per ogni $p \in \mathbb{N}$, X ha momento di ordine p finito e vale*

$$\|X\|_{L^p} = \sqrt{2} \frac{\Gamma\left(\frac{1+p}{2}\right)}{\Gamma\left(\frac{1}{2}\right)}$$

(iii) *$\|X\|_{L^p} = O(\sqrt{p})$ per $p \rightarrow +\infty$*

(iv) *Per ogni $\lambda \in \mathbb{R}$ vale*

$$\mathbb{E}[e^{\lambda X}] = e^{\frac{\lambda^2}{2}}$$

Dimostrazione. (cenni)

(i) Se $t \geq 1$ usando la Proposizione 7.1 e notando che $\sqrt{\frac{2}{\pi}} \leq 1$ si ottiene

$$P(X \geq t) \leq e^{-\frac{t^2}{2}}$$

si conclude usando la simmetria della distribuzione normale standard.

Se $0 \leq t < 1$ allora notiamo che il termine di destra è maggiore di 1 e dunque la disuguaglianza è banalmente vera (il membro di sinistra è una probabilità)

(ii) Segue da semplici cambi di variabili negli integrali.

(iii) Si usa la formula generalizzata di Stirling per $\Gamma(z)$ per $z \gg 1$

7.2 Variabili aleatorie subgaussiane

Proposizione 7.3. *Sia X v.a. reale. Allora i seguenti fatti sono equivalenti*

(i) $\exists k_1 > 0$ tale che

$$\mathbb{P}(|X| \geq t) \leq 2 \exp\left(-\frac{t^2}{k_1^2}\right)$$

(ii) $\exists k_2 > 0$ tale che

$$\|X\|_{L^p} \leq k_2 \sqrt{p}$$

(iii) $\exists k_3 > 0$ tale che

$$\mathbb{E}[\exp(\lambda^2 X^2)] \leq \exp(k_3^2 \lambda^2) \quad \forall |\lambda| \leq \frac{1}{k_3}$$

(iv) $\exists k_4 > 0$ tale che

$$\mathbb{E}\left[\exp\left(\frac{X^2}{k_4}\right)\right] \leq 2$$

Inoltre se X è centrata, i fatti precedenti sono equivalenti a

(v) $\exists k_5 > 0$ tale che

$$\mathbb{E}[\exp(\lambda X)] \leq \exp(k_5^2 \lambda^2) \quad \forall \lambda \in \mathbb{R}$$

In aggiunta, esistono delle costanti assolute calcolabili C_{ij} tali che

$$K_i \leq C_{ij} K_j \quad \forall i, j = 1, \dots, 4, (5)$$

Osservazione 21. Dalla Proposizione 7.2 sappiamo che se $X \sim \mathcal{N}(0, 1)$ allora valgono le condizioni (i), (ii) e (v) (e dunque anche le altre)

Osservazione 22. Se la v.a. non è centrata la proprietà (v) non può valere. Usando la disuguaglianza di Jensen (Teorema 1.6) con $\varphi(t) = e^{\lambda t}$ otteniamo

$$\mathbb{E}[\exp(\lambda X)] \geq e^{\lambda \mathbb{E}[X]} \quad \forall \lambda \in \mathbb{R}$$

Ora sviluppando in un intorno di 0 (e dunque per λ piccolo) si ha

$$e^{\lambda \mathbb{E}[X]} = 1 + \lambda \mathbb{E}[X] + o(\lambda)$$

$$e^{k_5^2 \lambda^2} = 1 + o(\lambda)$$

Dunque se valesse (v) si avrebbe

$$1 + \lambda \mathbb{E}[X] + o(\lambda) \leq 1 + o(\lambda)$$

il che è assurdo □

Definizione 7.2. Data X v.a. reale, definiamo la sua **seminorma subgaussiana** come

$$\|X\|_{\psi_2} = \inf \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq 2 \right\}$$

con la convenzione $\inf \emptyset = +\infty$

Definizione 7.3. Una v.a. reale X è detta subgaussiana se $\|X\|_{\psi_2} < +\infty$

Osservazione 23. Dall'Osservazione 21 otteniamo che $X \sim \mathcal{N}(0, 1)$ è subgaussiana.

Lemma 7.4. *Sia X v.a. reale.*

$$\|X\|_{\psi_2} = 0 \quad \Leftrightarrow \quad X = 0 \text{ q.c.}$$

Dimostrazione. \Leftarrow Se $X = 0$ q.c. allora

$$\left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq 2 \right\} = \{ t > 0 \mid \mathbb{E} [e^0] \leq 2 \} = (0, +\infty)$$

e dunque $\|X\|_{\psi_2} = \inf_{t \in (0, +\infty)} t = 0$.

\Rightarrow Dimostriamo la tesi in maniera contronominale.

Supponiamo che $\mathbb{P}(X = 0) \neq 1$, dunque $\exists a > 0$ con $\mathbb{P}(|X| > a) > 0$. Fissato $t > 0$ allora

$$\mathbb{E} \left[\exp \frac{X^2}{t^2} \right] \geq \mathbb{P}(|X| > a) \exp \left(\frac{a^2}{t^2} \right) \rightarrow +\infty \quad \text{per } t \downarrow 0$$

Dunque $\left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq 2 \right\}$ non può contenere $(0, \varepsilon)$ per un certo $\varepsilon > 0$ da cui $\|X\|_{\psi_2} > 0$. □

Lemma 7.5. *Se $\|X\|_{\psi_2} \in (0, +\infty)$ allora*

$$\|X\|_{\psi_2} = \min \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq 2 \right\}$$

Dimostrazione. Per definizione di norma subgaussiana

$$\|X\|_{\psi_2} = \inf \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq 2 \right\} = t_*$$

dunque esiste una successione $t_n \downarrow t_*$ tale che

$$\mathbb{E} \left[\exp \left(\frac{X^2}{t_n^2} \right) \right] \leq 2$$

Poichè t_n è decrescente si ha che

$$\exp \left(\frac{X^2}{t_n^2} \right) \leq \exp \left(\frac{X^2}{t_{n+1}^2} \right)$$

e dunque per il Teorema di Beppo-Levi si ha

$$\mathbb{E} \left[\exp \left(\frac{X^2}{t_*^2} \right) \right] = \lim_{n \rightarrow +\infty} \mathbb{E} \left[\exp \left(\frac{X^2}{t_n^2} \right) \right] \leq 2$$

ovvero $t_* \in \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq 2 \right\}$ ed è dunque un minimo. □

Teorema 7.6. *L'insieme delle v.a. subgaussiane definite su un fissato spazio di probabilità (con l'identificazione $X \sim Y$ se $X = Y$ q.o) sono uno spazio vettoriale. La norma subgaussiana rende tale spazio uno spazio di Banach.*

Dimostrazione. Denotiamo con \mathcal{S} l'insieme delle v.a. subgaussiane quozientato per la relazione di essere uguali quasi certamente. Proveremo che \mathcal{S} è normato dalla norma subgaussiana (che dunque è una norma), non proveremo che è un Banach.

- Dal Lemma 7.4 sappiamo che $\|X\|_{\psi_2} = 0 \iff X \sim 0$

- Sia $a \in \mathbb{R}$ e $X \in \mathcal{S}$

$$\|aX\|_{\psi_2} = \inf \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{a^2 X^2}{t^2} \right) \right] \leq 2 \right\} = |a| \inf \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{s^2} \right) \right] \leq 2 \right\} = |a| \|X\|_{\psi_2}$$

dove la seconda uguaglianza deriva dal cambio di variabili $t = |a|s$

- Siano $X, Y \in \mathcal{S}$, proviamo che vale la disuguaglianza triangolare. Possiamo supporre $X, Y \not\sim 0$ infatti se $X \sim 0$ allora otteniamo $X + Y \sim Y$ e la tesi segue banalmente.

Supponiamo dunque che $\|X\|_{\psi_2}, \|Y\|_{\psi_2} \in (0, +\infty)$ e quindi per la Proposizione 7.5 si ha

$$a = \|X\|_{\psi_2} = \min \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq 2 \right\}$$

$$b = \|Y\|_{\psi_2} = \min \left\{ t > 0 \mid \mathbb{E} \left[\exp \left(\frac{Y^2}{t^2} \right) \right] \leq 2 \right\}$$

Sia $\varphi(t) = e^{t^2}$ allora poichè tale funzione è convessa si ha

$$\varphi \left(\frac{X+Y}{a+b} \right) \leq \frac{a}{a+b} \varphi \left(\frac{X}{a} \right) + \frac{b}{a+b} \varphi \left(\frac{Y}{b} \right)$$

e dunque

$$\begin{aligned} \mathbb{E} \left[\exp \left(\frac{X+Y}{a+b} \right)^2 \right] &= \mathbb{E} \left[\varphi \left(\frac{X+Y}{a+b} \right) \right] \leq \frac{a}{a+b} \mathbb{E} \left[\varphi \left(\frac{X}{a} \right) \right] + \frac{b}{a+b} \mathbb{E} \left[\varphi \left(\frac{Y}{b} \right) \right] \leq \\ &\leq \frac{a}{a+b} 2 + \frac{b}{a+b} 2 \leq 2 \end{aligned}$$

e dunque per definizione di norma subgaussiana si ha

$$\|X+Y\|_{\psi_2} \leq a+b = \|X\|_{\psi_2} + \|Y\|_{\psi_2}$$

□

Osservazione 24. Sia $X \not\sim 0$ subgaussiana allora $\|X\|_{\psi_2}$ è la migliore costante k_4 nella Proposizione 7.3 ed inoltre per la seconda parte della stessa dimostrazione, sappiamo che esiste una costante assoluta tale che

$$P(|X| > t) \leq 2 \exp \left(-C \frac{t^2}{\|X\|_{\psi_2}^2} \right)$$

$$\|X\|_{L^p} \leq C \|X\|_{\psi_2} \sqrt{p} \text{ con } p > 1$$

e aggiungendo X centrata ottengo

$$\mathbb{E} [\exp(\lambda X)] \leq \exp \left(C \|X\|_{\psi_2}^2 \lambda^2 \right) \quad \forall \lambda \in \mathbb{R}$$

Proposizione 7.7. *Se X è una v.a. subgaussiana allora*

$$\|X - \mathbb{E}[X]\|_{\psi_2} \leq C \|X\|_{\psi_2}$$

dove C è una costante assoluta.

Dimostrazione. Essendo la norma subgaussiana una norma si ha

$$\|X - \mathbb{E}[X]\|_{\psi_2} \leq \|X\|_{\psi_2} + \|\mathbb{E}[X]\|_{\psi_2} = \|X\|_{\psi_2} + |\mathbb{E}[X]| \|1\|_{\psi_2} = \|X\|_{\psi_2} + \tilde{C} |\mathbb{E}[X]|$$

Ora

$$|\mathbb{E}[X]| \leq \mathbb{E}[|X|] = \|X\|_{L^1} \leq \hat{C} \|X\|_{\psi_2}$$

dove per l'ultima disuguaglianza abbiamo usato che per X subgaussiana vale

$$\|X\|_{L^p} \leq \hat{C} \|X\|_{\psi_2} \sqrt{p}$$

con $p = 1$.

□

Proposizione 7.8. *Siano X_1, \dots, X_n v.a. subgaussiane indipendenti e centrate. Allora*

$$\left\| \sum_{i=1}^n X_i \right\|_{\psi_2}^2 \leq C \sum_{i=1}^n \|X_i\|_{\psi_2}^2$$

dove C è una costante assoluta.

Dimostrazione.

$$\begin{aligned} \mathbb{E} \left[\exp \left(\lambda \sum_{i=1}^n X_i \right) \right] &= \prod_{i=1}^n \mathbb{E} [\exp(\lambda X_i)] \leq \prod_{i=1}^n \exp(\tilde{C} \lambda^2 \|X_i\|_{\psi_2}^2) = \\ &= \exp \left(\tilde{C} \lambda^2 \sum_{i=1}^n \|X_i\|_{\psi_2}^2 \right) \end{aligned}$$

dove l'ultima disuguaglianza deriva dall'Osservazione 24.

Abbiamo provato che $\sum X_i$ (che è centrata) soddisfa la condizione (v) della Proposizione 7.3 con

$$k_5 = \tilde{C} \sum_{i=1}^n \|X_i\|_{\psi_2}^2$$

Ora dalla seconda parte della Proposizione 7.3 sappiamo che

$$k_4^2 \leq \hat{C} k_5^2 \leq \tilde{C} \hat{C} \sum_{i=1}^n \|X_i\|_{\psi_2}^2$$

si conclude ricordando che la norma subgaussiana è il migliore k_4

□

7.3 Disuguaglianza di Hoeffding

Teorema 7.9 (Disuguaglianza di Hoeffding per v.a. subgaussiane). *Siano X_1, \dots, X_n v.a. subgaussiane indipendenti e centrate. Allora $\forall t \geq 0$ vale*

$$\mathbb{P} \left(\left| \sum_{i=1}^n X_i \right| > t \right) \leq 2 \exp \left(-c \frac{t^2}{\sum_{i=1}^n \|X_i\|_{\psi_2}^2} \right)$$

Dimostrazione. Essendo l'insieme delle v.a. subgaussiane (con l'usuale identificazione q.c.) uno spazio vettoriale normato, $\sum X_i$ è subgaussiana e dunque per la Proposizione 7.3 si ha

$$\mathbb{P} \left(\left| \sum_{i=1}^n X_i \right| > t \right) \leq 2 \exp \left(-c \frac{t^2}{\|\sum_{i=1}^n X_i\|_{\psi_2}^2} \right)$$

la tesi segue applicando la disuguaglianza della proposizione precedente. □

Corollario 7.10. *Siano X_1, \dots, X_n v.a. subgaussiane indipendenti e centrate e $\alpha_1, \dots, \alpha_n \in \mathbb{R}$ (non tutti nulli). Allora $\forall t > 0$ vale*

$$\mathbb{P} \left(\left| \sum_{i=1}^n \alpha_i X_i \right| > t \right) \leq 2 \exp \left(-C \frac{t^2}{K^2 \|\alpha\|_2^2} \right)$$

dove

- C è una costante assoluta
- $K = \max \|X_i\|_{\psi_2}$

Dimostrazione. Applicando la disuguaglianza di Hoeffding alle variabili $\alpha_1 X_1, \dots, \alpha_n X_n$ (anch'esse centrate, subgaussiane e indipendenti) otteniamo

$$\mathbb{P} \left(\left| \sum_{i=1}^n \alpha_i X_i \right| > t \right) \leq 2 \exp \left(-C \frac{t^2}{\sum_{i=1}^n \|\alpha_i X_i\|_{\psi_2}^2} \right)$$

e poichè $\|\cdot\|_{\psi_2}$ è una norma si ha

$$\sum_{i=1}^n \|\alpha_i X_i\|_{\psi_2}^2 = \sum_{i=1}^n \alpha_i^2 \|X_i\|_{\psi_2}^2 \leq K^2 \|\alpha\|_2^2$$

da cui la tesi. □

Osservazione 25. Se X_1, \dots, X_n sono subgaussiane indipendenti posso applicare la disuguaglianza di Hoeffding alle v.a. centrate $X_1 - \mathbb{E}[X_1], \dots, X_n - \mathbb{E}[X_n]$ e usare la seguente proposizione per stimare la norma subgaussiana della v.a. centrata

Teorema 7.11 (Disuguaglianza di Hoeffding per v.a. di Rademacher). *Siano X_1, \dots, X_n delle v.a. di Rademacher indipendenti e $\alpha \in \mathbb{R}^n$. Allora $\forall t \geq 0$ vale*

$$\mathbb{P} \left(\sum_{i=1}^n \alpha_i X_i \geq t \right) \leq \exp \left(-\frac{t^2}{2 \|\alpha\|_2^2} \right)$$

Dimostrazione. Fissato $\lambda > 0$ si ha

$$\begin{aligned} \mathbb{P}\left(\sum_{i=1}^n \alpha_i X_i \geq t\right) &= \mathbb{P}\left(\exp\left(\lambda \sum_{i=1}^n \alpha_i X_i\right) \geq e^{\lambda t}\right) \leq_1 \\ &\leq_1 e^{-\lambda t} \mathbb{E}\left[\exp\left(\lambda \sum_{i=1}^n \alpha_i X_i\right)\right] = e^{-\lambda t} \prod_{i=1}^n \mathbb{E}[\exp(\lambda \alpha_i X_i)] = \\ &= e^{-\lambda t} \prod_{i=1}^n \frac{1}{2} (e^{\lambda \alpha_i} + e^{-\lambda \alpha_i}) = e^{-\lambda t} \prod_{i=1}^n \cosh(\lambda \alpha_i) \leq_2 \\ &\leq_2 e^{-\lambda t} \prod_{i=1}^n \exp\left(\frac{\lambda^2 \alpha_i^2}{2}\right) = \exp\left(-\lambda t + \frac{\lambda}{2} \|\alpha\|_2^2\right) = \exp(f(\lambda)) \end{aligned}$$

dove

- \leq_1 è la disuguaglianza di Markov.
- \leq_2 si ottiene usando $\cosh(x) \leq e^{\frac{x^2}{2}}$

Ora

$$\arg \min_{\lambda} f(\lambda) := \lambda_{opt} = \frac{t}{\|\alpha\|_2^2}$$

e dunque si ha

$$\mathbb{P}\left(\sum_{i=1}^n \alpha_i X_i \geq t\right) \leq e^{f(\lambda_{opt})} = \exp\left(-\frac{t^2}{2\|\alpha\|_2^2}\right)$$

□

Corollario 7.12 (Disuguaglianza di Hoeffding bilatera per v.a. di Rademacher). *Siano X_1, \dots, X_n delle v.a. di Rademacher indipendenti e $\alpha \in \mathbb{R}^n$. Allora $\forall t \geq 0$ vale*

$$\mathbb{P}\left(\left|\sum_{i=1}^n \alpha_i X_i\right| \geq t\right) \leq 2 \exp\left(-\frac{t^2}{2\|\alpha\|_2^2}\right)$$

Dimostrazione. Siccome $X_i \sim -X_i$ si ha

$$\mathbb{P}\left(\sum_{i=1}^n \alpha_i X_i \leq -t\right) = \mathbb{P}\left(\sum_{i=1}^n \alpha_i (-X_i) \geq t\right) = \mathbb{P}\left(\sum_{i=1}^n \alpha_i X_i \geq t\right)$$

Si conclude notando che

$$\left\{\left|\sum_{i=1}^n \alpha_i X_i\right| \geq t\right\} \subseteq \left\{\sum_{i=1}^n \alpha_i X_i \geq t\right\} \cup \left\{\sum_{i=1}^n \alpha_i X_i \leq -t\right\}$$

□

Notiamo che se $Y \sim \text{Bernoulli}\left(\frac{1}{2}\right)$ allora $2Y - 1$ sono variabili di Rademacher dunque possiamo riformulare i risultati precedenti come

Corollario 7.13. *Sia Y_1, \dots, Y_n v.a. di Bernoulli $\left(\frac{1}{2}\right)$ indipendenti. Sia $a \in \mathbb{R}^n$ allora vale*

$$\begin{aligned} \mathbb{P}\left(\sum_{i=1}^n a_i \left(Y_i - \frac{1}{2}\right) > t\right) &\leq \exp\left(-2\frac{t^2}{\|a\|_2^2}\right) \\ \mathbb{P}\left(\left|\sum_{i=1}^n a_i \left(Y_i - \frac{1}{2}\right)\right| > t\right) &\leq 2 \exp\left(-2\frac{t^2}{\|a\|_2^2}\right) \end{aligned}$$

Dimostrazione. Se poniamo $X_i = 2Y_i - 1$ allora X_1, \dots, X_n sono variabili di Rademacher indipendenti. Notiamo che

$$\sum_{i=1}^n a_i \left(Y_i - \frac{1}{2} \right) = \frac{1}{2} \sum_{i=1}^n a_i X_i$$

e dunque applicando la disuguaglianza di Hoeffding per le v.a. di Rademacher si ottiene

$$\mathbb{P} \left(\sum_{i=1}^n a_i \left(Y_i - \frac{1}{2} \right) > t \right) = \mathbb{P} \left(\sum_{i=1}^n a_i X_i > 2t \right) \geq \exp \left(-\frac{2t^2}{\|a\|_2^2} \right)$$

Per la disuguaglianza bilatera basta osservare che $Y_i - \frac{1}{2}$ sono v.a. simmetriche. □

Teorema 7.14 (Disuguaglianza di Hoeffding per v.a. limitate). *Siano X_1, \dots, X_n v.a. limitate e indipendenti con $X_i \sim [m_i, M_i]$. Allora $\forall t \geq 0$ vale*

$$\mathbb{P} \left(\sum_{i=1}^N (X_i - \mathbb{E}[X_i]) \geq t \right) \leq \exp \left(-\frac{2t^2}{\sum_{i=1}^n (M_i - m_i)^2} \right)$$

Osservazione 26 (Potenziamento di algoritmi randomizzati). Supponiamo di avere un algoritmo randomizzato che da risposte corrette ad un problema di decisione con probabilità di $\frac{1}{2} + \delta$. Se facciamo girare l'algoritmo un numero N dispari di volte e scegliamo come decisione finale quella più frequente otteniamo che $\forall \varepsilon \in (0, 1)$ si ha

$$N > \frac{1}{2\delta^2} \ln \left(\frac{1}{\varepsilon} \right) \quad \Rightarrow \quad \mathbb{P}(\text{la decisione finale è corretta}) \geq 1 - \varepsilon$$

Dimostrazione. Segue dalla disuguaglianza di Hoeffding applicata a v.a. limitate. Siano X_1, \dots, X_N v.a. di Bernoulli di parametro $\frac{1}{2} - \delta$ allora

$$\mathbb{P}(\text{la decisione finale è sbagliata}) = \mathbb{P} \left(\sum_{i=1}^N X_i \geq \frac{N+1}{2} \right)$$

Ora

$$\left\{ \sum_{i=1}^N X_i \geq \frac{N+1}{2} \right\} = \left\{ \sum_{i=1}^N X_i - \left(\frac{1}{2} - \delta \right) \geq \frac{N+1}{2} - N \left(\frac{1}{2} - \delta \right) \right\}$$

e dunque applicando la disuguaglianza di Hoeffding con $t = \frac{1}{2} + \delta N$ si ha

$$\mathbb{P} \left(\sum X_i \geq \frac{M+1}{2} \right) \leq \exp \left(-2 \frac{\left(\frac{1}{2} + \delta N \right)^2}{N} \right) \leq \exp \left(-2 \frac{\delta^2 N^2}{N} \right) = \exp(-2\delta^2 N)$$

Ora una semplice verifica, prova che se vale la relazione tra N e ε si ha la tesi. □

8 Norme di matrici

8.1 Norma operatoriale per matrici

Definizione 8.1. Sia $A \in \mathbb{R}^{m \times n}$ allora definiamo la norma operatoriale di A come

$$\|A\| = \sup_{x \in \mathbb{R}^n} \frac{\|Ax\|_2}{\|x\|_2} = \max_{\substack{x \in \mathbb{R}^n \\ \|x\|=1}} \|Ax\|_2$$

Lemma 8.1. Sia $A \in \mathbb{R}^{m \times n}$ allora vale

$$\|A\| = \max_{\substack{x \in S^{n-1} \\ y \in S^{m-1}}} \langle Ax, y \rangle$$

Lemma 8.2. Sia $A \in \mathbb{R}^{m \times n}$ e $\varepsilon \in (0, 1)$ allora se N è un ε -net di S^{n-1} si ha

$$\sup_{x \in N} \|Ax\|_2 \leq \|A\| \leq \frac{1}{1 - \varepsilon} \sup_{x \in N} \|Ax\|_2$$

Dimostrazione. La prima disuguaglianza segue banalmente dalla definizione infatti $N \subseteq S^{n-1}$. Proviamo la seconda disuguaglianza.

Per definizione di norma operatoriale

$$\exists x \in S^{n-1} \quad \|Ax\|_2 = \|A\|$$

Per definizione di ε -net, esiste $x_0 \in N$ tale che $\|x - x_0\|_2 \leq \varepsilon$ dunque otteniamo

$$\|Ax - Ax_0\|_2 \leq \|A\| \varepsilon$$

e utilizzando la disuguaglianza triangolare si ha

$$\|Ax_0\|_2 \geq \|Ax\|_2 - \|Ax - Ax_0\|_2 \geq \|A\| - \varepsilon \|A\| = (1 - \varepsilon) \|A\|$$

e dunque otteniamo

$$\|A\| \leq \frac{1}{1 - \varepsilon} \|Ax_0\|_2 \leq \frac{1}{1 - \varepsilon} \sup_{x' \in N} \|Ax'\|_2$$

□

Lemma 8.3. Sia $A \in \mathbb{R}^{m \times n}$. Dato $\varepsilon \in [0, \frac{1}{2})$, siano N e M ε -net rispettivamente di S^{n-1} e S^{m-1} vale

$$\sup_{\substack{x \in N \\ y \in M}} \langle Ax, y \rangle \leq \|A\| \leq \frac{1}{1 - 2\varepsilon} \sup_{\substack{x \in N \\ y \in M}} \langle Ax, y \rangle$$

Dimostrazione. Per il Lemma 8.1 si ha

$$\|A\| = \sup_{\substack{x \in S^{n-1} \\ y \in S^{m-1}}} \langle Ax, y \rangle$$

e per il Teorema di Weistrass tale sup è un massimo, dunque

$$\exists x \in S^{n-1} \quad \exists y \in S^{m-1} \quad \|A\| = \langle Ax, y \rangle$$

Ora per definizione di ε -net otteniamo che

$$\begin{aligned} \exists x_0 \in N \quad & \|x - x_0\|_2 \leq \varepsilon \\ \exists y_0 \in M \quad & \|y - y_0\|_2 \leq \varepsilon \end{aligned}$$

Dunque si ha

$$\begin{aligned} |\langle Ax, y \rangle - \langle Ax_0, y_0 \rangle| &= |\langle A(x - x_0), y \rangle - \langle Ax_0, y - y_0 \rangle| \leq \\ &\leq \|A\| \|x - x_0\|_2 \|y\|_2 + \|A\| \|x_0\|_2 \|y - y_0\|_2 \end{aligned}$$

Ricordando che $\|y\|_2 = \|x_0\|_2 = 1$ otteniamo la tesi.

□

8.2 Norme di matrici subgaussiane

Teorema 8.4. *Sia $A \in \mathbb{R}^{m \times n}$ con entrate indipendenti, subgaussiane e centrate. Allora $\forall t > 0$ vale*

$$\mathbb{P}(\|A\| \leq CK(\sqrt{m} + \sqrt{n} + t)) \leq 1 - 2e^{-t^2}$$

dove C è una costante assoluta e $K = \max_{i,j} \|A_{ij}\|_{\psi_2}$

Dimostrazione. La dimostrazione procede per passi.

- Fissato $\varepsilon = \frac{1}{4}$, siano N e M ε -net ottimali rispettivamente di S^{n-1} e S^{m-1} . Per il Lemma precedente, vale

$$\|A\| \leq 2 \max_{\substack{x \in N \\ y \in M}} \langle Ax, y \rangle \quad (5)$$

- Fissati x, y si ha

$$\langle Ax, y \rangle = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i y_j$$

e quindi per la Proposizione 7.8 otteniamo

$$\begin{aligned} \|\langle Ax, y \rangle\|_{\psi_2}^2 &\leq C \sum_{i=1}^n \sum_{j=1}^n \|A_{ij} x_i y_j\|_{\psi_2}^2 = C \sum_{i=1}^n \sum_{j=1}^n x_i^2 y_j^2 \|A_{ij}\|_{\psi_2}^2 \leq \\ &\leq CK^2 \sum_{i=1}^n x_i^2 \sum_{j=1}^n y_j^2 = CK^2 \end{aligned}$$

dove abbiamo utilizzato che $\|x\|_2 = \|y\|_2 = 1$.

Per l'Osservazione 24 si ha

$$\mathbb{P}(\langle Ax, y \rangle \geq u) \leq 2 \exp\left(-\frac{cu^2}{K^2}\right)$$

•

$$\begin{aligned} \mathbb{P}\left(\max_{\substack{x \in N \\ y \in M}} \langle Ax, y \rangle \geq u\right) &= \mathbb{P}\left(\bigcup_{\substack{x \in N \\ y \in M}} \{\langle Ax, y \rangle \geq u\}\right) \leq \\ &\leq \sum_{\substack{x \in N \\ y \in M}} \mathbb{P}(\langle Ax, y \rangle \geq u) \leq 9^{n+m} 2 \exp\left(-\frac{cu^2}{K^2}\right) \end{aligned} \quad (6)$$

dove per l'ultima disuguaglianza abbiamo usato che il numero d'impacchettamento di S^{k-1} è stimato dall'alto da $(1 + \frac{2}{\varepsilon})^k$

Dunque usando (5) si ha

$$\mathbb{P}(\|A\| \leq CK(\sqrt{m} + \sqrt{n} + t)) \leq \mathbb{P}\left(2 \max_{\substack{x \in N \\ y \in M}} \langle Ax, y \rangle \leq CK(\sqrt{m} + \sqrt{n} + t)\right)$$

Ora usando (6) otteniamo

$$\begin{aligned} &\mathbb{P}\left(2 \max_{\substack{x \in N \\ y \in M}} \langle Ax, y \rangle \geq CK(\sqrt{m} + \sqrt{n} + t)\right) \leq \\ &\leq 9^{n+m} 2 \exp\left(-c \frac{C^2}{4} (\sqrt{n} + \sqrt{m} + t)^2\right) \leq 9^{n+m} 2 \exp\left(-c \frac{C^2}{4} (n + m + t^2)\right) \end{aligned}$$

e per C abbastanza grande possiamo supporre

$$9^{n+m} \exp\left(-c\frac{C^2}{4}(n+m)\right) \leq 1$$

$$\exp\left(-c\frac{C^2}{4}t^2\right) \leq e^{-t^2}$$

da cui la tesi. □

Corollario 8.5. *Sia $A \in \mathbb{R}^{n \times n}$ una matrice simmetrica con entrate subgaussiane e centrate. Inoltre se le entrate della parte triangolare superiore sono indipendenti vale*

$$\mathbb{P}(\|A\| \leq CK(\sqrt{n} + t)) \geq 1 - 4e^{-t^2}$$

dove C è una costante assoluta e $K = \max \|A_{ij}\|_{\psi_2}$

Dimostrazione. Chiamata A^+ la parte triangolare superiore e A^- la parte strettamente triangolare inferiore si ha che $A = A^+ + A^-$ ed inoltre entrambe le matrici soddisfano le ipotesi del Teorema precedente da cui

$$\mathbb{P}\left(\|A^+\| \geq \frac{C}{2}(\sqrt{n} + t)\right) \leq 2e^{-t^2}$$

$$\mathbb{P}\left(\|A^-\| \geq \frac{C}{2}(\sqrt{n} + t)\right) \leq 2e^{-t^2}$$

Usando la disuguaglianza triangolare si ha

$$\|A\| \geq D \quad \Rightarrow \quad \left(\|A^+\| \geq \frac{D}{2} \text{ o } \|A^-\| \geq \frac{D}{2}\right)$$

e dunque

$$\mathbb{P}(\|A\| \geq CK(\sqrt{n} + t)) \leq \mathbb{P}\left(\|A^+\| \geq \frac{C}{2}(\sqrt{n} + t)\right) + \mathbb{P}\left(\|A^-\| \geq \frac{C}{2}(\sqrt{n} + t)\right) \leq 4e^{-t^2}$$

□

9 Teoria perturbativa di matrici simmetriche

Data una matrice $S \in \mathbb{R}^{n \times n}$ simmetrica, posso ordinare i suoi n autovalori reali come

$$\lambda_1(S) \geq \cdots \geq \lambda_n(S)$$

Teorema 9.1 (Teorema min-max di Courant-Fisher). *Sia $S \in \mathbb{R}^{n \times n}$ una matrice simmetrica allora*

$$\lambda_i(S) = \max_{\substack{E \subseteq \mathbb{R}^n \\ \dim E = i}} \min_{\substack{x \in E \\ \|x\|_2 = 1}} \langle Sx, x \rangle$$

Corollario 9.2 (Disuguaglianza di Weyl). *Siano $S, T \in \mathbb{R}^{n \times n}$ due matrici simmetriche. Allora vale*

$$|\lambda_i(S) - \lambda_i(T)| \leq \|S - T\| \quad \forall i = 1, \dots, n$$

Definizione 9.1. Siano $x, y \in \mathbb{R}^n$. Definiamo l'**angolo** tra i due vettori come

$$\angle(x, y) = \arccos \left(\frac{\langle x, y \rangle}{\|x\|_2 \|y\|_2} \right)$$

Teorema 9.3 (di Davis-Kohan). *Siano $S, T \in \mathbb{R}^{n \times n}$ due matrici simmetriche. Supponiamo che $\lambda_i(S)$ sia semplice e definiamo*

$$\delta = \min_{j \neq i} |\lambda_j(S) - \lambda_i(S)|$$

Allora fissati due autovettori unitari $v_i(S)$ e $v_i(T)$ relativi agli autovalori $\lambda_i(S)$ e $\lambda_i(T)$ vale

$$\sin(\angle(v_i(T), v_i(S))) \leq 2 \frac{\|T - S\|}{\delta}$$

Proposizione 9.4. *La disuguaglianza DK implica che $\exists \theta \in \{-1, 1\}$ tale che*

$$\|v_i(S) - \theta v_i(T)\|_2 \leq \sqrt{8} \frac{\|T - S\|}{\delta}$$

10 Cluster Analysis

10.1 Two blocks models

Definizione 10.1. Sia $V = C_1 \cup C_2$ con $|C_1| = |C_2| = \frac{n}{2}$ definiamo con $G(n, p, q) = (V, E)$ il grafo random tale che

$$\forall \{x, y\} \subseteq V \quad \mathbb{P}(\{x, y\} \in E) = \begin{cases} p & \text{se } x, y \in C_1 \text{ o } x, y \in C_2 \\ q & \text{altrimenti} \end{cases}.$$

Cerchiamo un algoritmo che data una realizzazione di $G(n, p, q)$ riesca ad individuare i due sottoinsiemi.

Lemma 10.1. *Detta A la matrice di adiacenza della realizzazione di un grafo $G(n, p, q)$ allora posta*

$$A = D + R \text{ dove } D = \mathbb{E}[A]$$

otteniamo che $rk(D)$ con autovalori

$$\lambda_1(D) = \frac{p+q}{2}n \quad \lambda_2(D) = \frac{p-q}{2}n$$

Inoltre i vettori $v_1(D) = (1 \ \dots \ 1)^T$ e $v_2(D) = (v_2(D)_i)$ con $v_2(D)_i = \begin{cases} 1 & \text{se } i \in C_1 \\ -1 & \text{se } i \in C_2 \end{cases}$ sono rispettivamente autovettori.

Dimostrazione. Possiamo supporre che $V = \{1, \dots, n\}$ e a meno di cambiare l'ordine dei vertici (e dunque eseguire un cambio di base), $C_1 = \{1, \dots, \frac{n}{2}\}$. Dunque esiste una matrice invertibile U tale che

$$UDU^{-1} = \tilde{D} = \left(\begin{array}{c|c} P & Q \\ \hline Q & P \end{array} \right) \text{ dove } P = p \begin{pmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{pmatrix} \quad Q = q \begin{pmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{pmatrix} \in \mathbb{R}^{\frac{n}{2} \times \frac{n}{2}}$$

Ora \tilde{D} è formata da copie di due colonne linearmente indipendenti e ha dunque rango 2 ed inoltre si mostra facilmente che

$$\tilde{D} \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = \frac{p+q}{2}n \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

$$\tilde{D} \begin{pmatrix} 1 \\ \vdots \\ 1 \\ -1 \\ \vdots \\ -1 \end{pmatrix} = \frac{p-q}{2}n \begin{pmatrix} 1 \\ \vdots \\ 1 \\ -1 \\ \vdots \\ -1 \end{pmatrix}$$

□

Spinti da questo Lemma, costruiamo l'algoritmo:

Input: A matrice di adiacenza

Output: partizione dei vertici del grafo in \mathcal{C} e \mathcal{C}^*

$v_2(A) \leftarrow$ autovettore (di norma 1) relativo al secondo autovalore di A ;

$\mathcal{C} \leftarrow \{i \in V \mid v_2(A)_i > 0\}$;

$\mathcal{C}^* \leftarrow \{i \in V \mid v_2(A)_i \leq 0\}$;

Algorithm 1: Spectral clustering algorithm

Lemma 10.2. *Esiste una costante assoluta C_0 tale che $\forall n \geq 1$ si ha*

$$\mathbb{P}(\|R\| \leq C_0\sqrt{n}) \geq 1 - 4e^{-n}$$

Dimostrazione. Utilizzando il Corollario 8.5 con $t = \sqrt{n}$ otteniamo che

$$\mathbb{P}(\|R\| \leq 2\tilde{C}K\sqrt{n}) \geq 1 - 4e^{-n} \quad (7)$$

dove \tilde{C} è una costante assoluta, mentre $K = \max \|R_{ij}\|_{\psi_2}$. Notiamo che $\|R_{ij}\|_{\infty} \leq 1$ essendo le entrate v.a. di Bernoulli centrate e quindi (per una stima vista METTI RIF) si ha

$$\|R_{ij}\|_{\psi_2} \leq \frac{\|R_{ij}\|_{\infty}}{\ln 2} \leq 1$$

dunque la tesi segue da (7) ponendo $C = 2\tilde{C}$. □

Definizione 10.2. Data una partizione dei vertici $\mathcal{C}, \mathcal{C}^*$ dei vertici definiamo

$$\Delta = \min \{ |C_1 \Delta \mathcal{C}|, |C_1 \Delta \mathcal{C}^*| \}$$

Osservazione 27. Poichè

$$C_1 \Delta \mathcal{C} = (C_1 \cap \mathcal{C}^*) \cup (C_2 \cap \mathcal{C})$$

$|C_1 \Delta \mathcal{C}|$ conta il numero di vertici classificati male se \mathcal{C} approssima C_1 e \mathcal{C}^* approssima C_2 .

La Δ definita sopra conta, dunque, la bontà dell'approssimazione.

Teorema 10.3. *Siano $p, q \in (0, 1)$ con $p > q$ e definiamo*

$$\mu = \min \left\{ q, \frac{p - q}{2} \right\}$$

Allora con probabilità $\geq 1 - 4e^{-n}$ lo spectral clustering algorithm fornisce come output una partizione $\mathcal{C}, \mathcal{C}^$ dei vertici tale che*

$$\Delta \leq \frac{C}{\mu^2}$$

dove C è una costante assoluta.

Dimostrazione. Applicando la Proposizione 9.4 alle matrici $S = D$ e $T = A$ con $i = 2$, otteniamo che $\exists \theta \in \{-1, 1\}$ tale che

$$\|v_2(D) - \theta v_2(A)\|_2 \leq \sqrt{8} \frac{\|D - A\|}{\mu n} = \frac{\sqrt{8}}{\mu n} \|R\| \quad (8)$$

infatti

$$\delta = \min_{j \neq 2} \{ |\lambda_j(D) - \lambda_2(D)| \} = \min \{ |\lambda_2(D)|, |\lambda_1(D) - \lambda_2(D)| \} = \min \left\{ q, \frac{p - q}{2} \right\} n = \mu n$$

Moltiplicando (8) per \sqrt{n} otteniamo

$$\|u_2(D) - \theta u_2(A)\|_2 \leq \frac{\sqrt{8}}{\mu n} \cdot \frac{\|R\|}{\sqrt{n}} \quad (9)$$

dove $u_2(D)$ è l'autovettore del Lemma 10.1 e $u_2(A) = \sqrt{n}v_2(A)$.

Se ci mettiamo nell'evento $\{\|R\| \leq C_0\sqrt{n}\}$ che per il Lemma 10.2 ha probabilità $\geq 1 - 4e^{-n}$, l'equazione (9) diventa

$$\|u_2(D) - \theta u_2(A)\|_2 \leq \frac{\sqrt{8}C_0}{\mu} = \frac{\sqrt{C}}{\mu}$$

Proviamo adesso che

$$\Delta \leq \|u_2(D) - \theta u_2(A)\|_2^2$$

il che conclude la dimostrazione.

- $\theta = 1$.

$$j \in C_1 \cap \mathcal{C}^* \Rightarrow (u_2(D)_i = +1 \text{ e } u_2(A)_i \leq 0) \Rightarrow (u_2(D)_i - u_2(A)_i)^2 \geq 1$$

$$j \in C_2 \cap \mathcal{C} \Rightarrow (u_2(D)_i = -1 \text{ e } u_2(A)_i \geq 0) \Rightarrow (u_2(D)_i - u_2(A)_i)^2 \geq 1$$

e dunque

$$\begin{aligned} \Delta \leq |C_1 \Delta \mathcal{C}| &= |C_1 \cap \mathcal{C}^*| + |C_2 \cap \mathcal{C}| = \sum_{j \in (C_1 \cap \mathcal{C}^*) \cup (C_2 \cap \mathcal{C})} 1 \leq \\ &\leq \sum_{j=1}^n (u_2(D)_i - u_2(A)_i)^2 = \|u_2(D) - \theta u_2(A)\|_2^2 \end{aligned}$$

- $\theta = -1$.

Come sopra ma consideriamo $C_1 \Delta \mathcal{C}^*$

□

10.2 Cluster Analysis

Definizione 10.3. Dato un insieme $\mathcal{X} = \{x_1, \dots, x_N\} \subseteq \mathbb{R}^n$, una **funzione di dissimilarità** è una qualsiasi funzione d tale che

- $d(x, y) \geq 0$
- $d(x, y) = d(y, x)$

Nel seguito, per alleggerire la notazione, scriveremo

$$d(x_i, x_j) =: d_{ij}$$

Definizione 10.4. Fissato un naturale K , una suddivisione in K **cluster** è una qualsiasi mappa surgettiva

$$C : \{1, \dots, N\} \rightarrow \{1, \dots, K\}$$

sotto l'identificazione data dalla relazione di equivalenza

$$C \sim C' \Leftrightarrow \exists \sigma \in S_K \quad C = \sigma C'$$

Definizione 10.5. Dato una suddivisione C e una funzione di dissimilarità, definiamo la **loss function** come

$$W(C) = \frac{1}{2} \sum_{k=1}^K \sum_{\substack{i=1 \\ C(i)=k}}^n \sum_{\substack{j=1 \\ C(j)=k}}^N d_{ij}$$

Definiamo, inoltre, la quantità

$$B(C) = \frac{1}{2} \sum_{k=1}^K \sum_{\substack{i=1 \\ C(i)=k}}^n \sum_{\substack{j=1 \\ C(j) \neq k}}^n d_{ij}$$

Osservazione 28. La funzione di loss W misura la dispersione all'interno del cluster (*within-clusters point scatter*), mentre la funzione B misura la dispersione tra i punti di cluster differenti (*between-clusters point scatter*).

Il nostro obiettivo è trovare il clustering che minimizza la funzione di loss oppure quello che massimizza la funzione B . Il seguente lemma prova che è equivalente richiedere una tra le due condizioni

Lemma 10.4. *Per ogni cluster C vale*

$$B(C) + W(C) = \frac{1}{3} \sum_{i=1}^n \sum_{j=1}^N d_{ij}$$

Dimostrazione.

$$\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n d_{ij} = \frac{1}{2} \sum_{k=1}^K \sum_{\substack{i=1 \\ C(i)=k}}^n \left(\sum_{\substack{j=1 \\ C(j)=k}}^n d_{ij} + \sum_{\substack{j=1 \\ C(j) \neq k}}^n d_{ij} \right) = W(C) + B(C)$$

□

10.3 K-means

Consideriamo un caso particolare in cui $d(x, y) = \|x - y\|_2^2$ e d'ora in avanti, per alleggerire la notazione toglieremo il pedice alla norma.

Lemma 10.5. *Siano X, Y v.a. reali i.i.d.. Allora*

$$\text{Var}(X) = \frac{1}{2}\mathbb{E}[(X - Y)^2]$$

Dimostrazione.

$$\begin{aligned}\mathbb{E}[(X - Y)^2] &= \mathbb{E}[X^2] + \mathbb{E}[Y^2] - 2\mathbb{E}[XY] = \mathbb{E}[X^2] + \mathbb{E}[Y^2] - 2\mathbb{E}[X]\mathbb{E}[Y] = \\ &= 2\mathbb{E}[X^2] - 2\mathbb{E}[X]^2 = 2\text{Var}(X)\end{aligned}$$

□

Corollario 10.6. *Nel caso in cui $d(x, y) = \|x - y\|^2$ si ha*

$$W(C) = \sum_{i=1}^K N_k \sum_{\substack{i=1 \\ C(i)=k}}^N \|x_i - \bar{x}_k\|^2$$

dove

$$\begin{aligned}N_k &= |C^{-1}(\{k\})| \\ \bar{x}_k &= \frac{1}{N_k} \sum_{\substack{i=1 \\ C(i)=k}}^N x_i\end{aligned}$$

Dimostrazione. Denotiamo $x_i = (x_{i1}, \dots, x_{iN})$. Fissiamo k, α .

Consideriamo X a valori $\{x_{i\alpha} \mid C(i) = k\}$ che assume i valori con equal probabilità (assumiamo i valori $x_{i\alpha}$ tra loro distinti, senno la probabilità proporzionale al numero delle occorrenze) allora se $Y \sim X$ si ha

$$\begin{aligned}\text{Var}(X) &= \frac{1}{N_k} \sum_{\substack{i=1 \\ C(i)=k}}^N (x_{i\alpha} - \bar{x}_{k\alpha})^2 \\ \frac{1}{2}\mathbb{E}[(X - Y)^2] &= \frac{1}{2N_k} \sum_{\substack{i=1 \\ C(i)=k}}^N \sum_{\substack{j=1 \\ C(j)=k}}^N (x_{i\alpha} - x_{j\alpha})^2\end{aligned}$$

e dunque per il Lemma precedente

$$\frac{1}{N_k} \sum_{\substack{i=1 \\ C(i)=k}}^N (x_{i\alpha} - \bar{x}_{k\alpha})^2 = \frac{1}{2N_k} \sum_{\substack{i=1 \\ C(i)=k}}^N \sum_{\substack{j=1 \\ C(j)=k}}^N (x_{i\alpha} - x_{j\alpha})^2$$

Moltiplicando per N_k^2 l'equazione precedente, sommando per $\alpha = 1, \dots, N$ e $k = 1, \dots, K$ otteniamo la tesi.

□

Ricordando che

$$\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}[X])^2] = \min_{a \in \mathbb{R}} \mathbb{E}[(X - a)^2]$$

il Corollario precedente ci fornisce la seguente caratterizzazione variazionale: $\forall k, \alpha$

$$\frac{1}{N_k} \sum_{\substack{i=1 \\ C(i)=k}}^N (x_{i\alpha} - \bar{x}_{k\alpha})^2 = \min_{a \in \mathbb{R}} \left\{ \frac{1}{N_k} \sum_{\substack{i=1 \\ C(i)=k}}^N (x_{i\alpha} - a)^2 \right\} \quad (10)$$

e dunque

$$\frac{1}{N_k} \sum_{\substack{i=1 \\ C(i)=k}} \|x_i - \bar{x}_k\|^2 = \min_{a \in \mathbb{R}^n} \left\{ \sum_{\substack{i=1 \\ C(i)=k}} \|x_i - a\|^2 \right\}$$

Introduciamo una funzione loss estesa (ha più entrate)

$$W_e(C, m_1, \dots, m_K) = \sum_{k=1}^K N_k \sum_{\substack{i=1 \\ C(i)=k}} \|x_i - m_k\|^2$$

Per (10), fissata C

$$\min_{m_1, \dots, m_K \in \mathbb{R}^n} W_e(C, m_1, \dots, m_K) = W_e(C, \bar{x}_1, \dots, \bar{x}_K) = W(C)$$

dunque se $C_\star = \arg \min W(C)$ allora C_\star è la prima entrata del minimizzante di W_e . Per trovare il minimizzante di W , trovo quello di W_e .

L'algoritmo di K -means è un algoritmo discendente e si struttura come segue

Input: $\mathcal{X} = \{x_1, \dots, x_N\} \subseteq \mathbb{R}^n$ e d funzione di dissimilarità

Output: Suddivisione C

for $i = 1, \dots, K$ **do**

$j \leftarrow \text{random}(1, \dots, N)$;
 $m_i \leftarrow x_j$

end

while $C_{new} \neq C$ **do**

$C \leftarrow G_{new}$;
 for $i=1, \dots, N$ **do**
 $j \leftarrow \arg \min_{k=1, \dots, K} \|x_i - m_k\|$;
 $C_{new}(i) \leftarrow j$
 end
 for $k=1, \dots, K$ **do**
 $m_k \leftarrow \text{baricentro di } C_{new}^{-1}(k)$
 end

end

Algorithm 2: k -means algorithm

10.4 Unnormalize Laplacian spectral cluster

Definizione 10.6. Dato un grafo pesato $G = (V, E, W)$ definiamo **laplaciano** di G

$$L = D - W \text{ dove } D = \text{diag}(d_1, \dots, d_N) \quad d_i = \sum_{j=1}^N w_{ij}$$

Il nome del Laplaciano segue dalla seguente

Osservazione 29. Consideriamo una griglia toroidale in \mathbb{R}^n e

$$w_{ij} = \begin{cases} 1 & \text{se } i, j \text{ lato della griglia} \\ 0 & \text{altrimenti} \end{cases}$$

Se identifichiamo la funzione $f : V \rightarrow \mathbb{R}$ con il vettore di \mathbb{R}^N

$$\begin{pmatrix} f(x_1) \\ \vdots \\ f(x_N) \end{pmatrix} = \begin{pmatrix} f_1 \\ \vdots \\ f_N \end{pmatrix}$$

allora

$$(Lf)_i = (Df)_i - (Wf)_i = d_{ii}f_i - \sum_{j=1}^N w_{ij}f_j = 2nf_i - \sum_{\substack{j \\ \text{adiacente ad } i}} f_j = \sum_{\substack{j \\ \text{adiacentte adi}}} (f_j - f_i)$$

e dunque

$$\begin{aligned} (Lf)(x_i) &= \sum_j f(x_j) - f(x_i) = \sum_{\substack{j \\ \|x_i - x_j\|=1}} f(x_i) - f(x_j) = \\ &= \sum_{\alpha=1}^n f(x_i + e_\alpha) + f(x_i - e_\alpha) - 2f(x_i) \end{aligned}$$

ora l'ultima espressione è la discretizzazione del laplaciano.

Proposizione 10.7. *Il laplaciano L gode delle seguenti proprietà*

(i) $\forall f \in \mathbb{R}^N$

$$f \cdot Lf = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ij} (f_i - f_j)^2$$

(ii) L è una matrice simmetrica semidefinita positiva

(iii) Siano A_1, \dots, A_M le componenti connesse di G . Allora 0 è un autovalore di L con molteplicità M . Inoltre, il nucleo di L è generato dai vettori $1_{A_1}, \dots, 1_{A_M}$ dove

$$(1_{A_k})_i = \begin{cases} 1 & \text{se } i \in A_k \\ 0 & \text{altrimenti} \end{cases}$$

Dimostrazione.

(i)

$$\begin{aligned}
f \cdot Lf &= \sum_i f_i (Lf)_i = \sum_{i,j} f_i L_{ij} f_j = \sum_i d_{ii} f_i^2 - \sum_{i,j} w_{ij} f_i f_j = \\
&= \sum_i f_i^2 \left(\sum_j w_{ij} \right) - \sum_{i,j} w_{ij} f_i f_j = \\
&= \frac{1}{2} \left(\sum_{i,j} f_i^2 w_{ij} + \sum_{i,j} f_j^2 w_{ji} \right) - \frac{1}{2} \left(2 \sum_{i,j} w_{ij} f_i f_j \right) = \frac{1}{2} \sum_{i,j} w_{ij} (f_i - f_j)^2
\end{aligned}$$

dove abbiamo usato la simmetria di W

(ii) Poichè D, W sono simmetriche anche $L = D - W$ lo è. Ricordando che $w_{ij} \geq 0$ si ottiene che L è semidefinita positiva.

(iii) Se $f \in \text{Ker}(L)$ allora $f \cdot Lf = 0$. Ora

$$f \cdot Lf = 0 \Leftrightarrow \sum_{ij} w_{ij} (f_i - f_j)^2 = 0 \Leftrightarrow \forall i, j \ w_{ij} > 0 \quad f_i = f_j$$

Ovvero se $\{i, j\}$ è un lato di G , $f_i = f_j$ e dunque f deve essere costante sulle componenti connesse. Abbiamo provato che

$$f \in \text{Ker}L \Rightarrow f \text{ costante su } A_k \quad k = 1, \dots, M$$

Viceversa, se f è costante sulle componenti connesse si ha $Lf = 0$ essendo

$$(Lf)_i = \sum_j w_{ij} (f_i - f_j)$$

Osservazione 30. Siano v_1, \dots, v_n una base di $\text{Ker}L$ e $V = (v_1 \ \dots \ v_n)$. Diremo che $x \equiv y$ se la riga x -esima di V è uguale alla riga y -esima di V . Allora

$$x \equiv y \Leftrightarrow x, y \text{ stanno nella stessa componente connessa}$$

Dimostrazione. Sia $h_i = \frac{1_{A_i}}{|A_i|}$.

\Leftarrow Se x, y stanno nella stessa componente connessa allora $(h_i)_x = (h_i)_y$ per ogni $i = 1, \dots, M$. Ma $\{h_1, \dots, h_M\}$ sono una base del nucleo e dunque $\exists b_{ij}$ con

$$v_i = \sum_j b_{ij} h_j$$

da cui la tesi.

\Rightarrow $\forall k = 1, \dots, M$ fisso $x_k \in A_k$. Dato $w \in \mathbb{R}^N$ definisco $\tilde{w} \in \mathbb{R}^M$ dove

$$\tilde{w}_k = w_{x_k}$$

Notiamo che i vettori $\tilde{v}_1, \dots, \tilde{v}_M$ sono linearmente indipendenti (se non lo fossero, non lo sarebbero nemmeno i v_i) e dunque la matrice

$$V = (\tilde{v}_1 \ \dots \ \tilde{v}_M) \in \mathbb{R}^{M \times M}$$

non ha righe uguali. Abbiamo dunque provato che se V ha due righe uguali allora le righe corrispondono ad indici nella stessa componente connessa.

Input: G grafo con M componenti connesse.

Output: Componenti connesse C_1, \dots, C_M

$L \leftarrow$ laplaciano di G ;

for $i = 1, \dots, M$ **do**

$|$ $u_i \leftarrow$ i -esimo autovettore normalizzato ortogonale a u_j con $j < i$

end

$U \leftarrow (u_1, \dots, u_M)$;

$(\tilde{C}_1, \dots, \tilde{C}_m) \leftarrow$ M-means(U);

for $i = 1, \dots, M$ **do**

$|$ $C_i \leftarrow \{j \in [N] \mid u_j \in \tilde{C}_i\}$

end

Algorithm 3: Unnormalize Laplacian spectral cluster algorithm

Dalla proposizione e dall'osservazione segue l'Algoritmo 3

Definizione 10.7. Dato un insieme $\mathcal{X} = \{x_1, \dots, x_N\} \subseteq \mathbb{R}^n$, una **funzione di similarità** è una qualsiasi funzione s tale che

- $s(x, y) \in \mathbb{R}$
- $s(x, y) = s(y, x)$

Nel seguito, per alleggerire la notazione, scriveremo

$$s_{ij} := s(x_i, x_j)$$

Esempio 10.8. Alcune possibili scelte per tale funzione sono

1. Fissato $\varepsilon > 0$,

$$s_{ij} = \mathbb{1}_{\|x_i - x_j\| \leq \varepsilon}$$

2. Fissato K

$$s_{ij} = \mathbb{1}_{x_i \text{ è tra i primi } k\text{-primi vicini (in senso euclideo) a } x_j \text{ e viceversa}}$$

3. Fissato K

$$s_{ij} = \mathbb{1}_{x_i \text{ è tra i primi } k\text{-primi vicini (in senso euclideo) a } x_j \text{ o viceversa}}$$

4. Fissato $\sigma > 0$

$$s_{ij} = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

Dato un insieme di dati e una funzione di similarità, possiamo definire un grafo pesato $G = (V, E, P)$ dove

$$V = \{1, \dots, N\}$$

$$\{i, j\} \in E \iff w_{ij} = f(s_{ij}) > 0$$

con $f : \mathbb{R} \rightarrow [0, +\infty)$.

Osservazione 31. Tipicamente quando si usano le funzioni di similarità di tipo 1. 2. o 3. la funzione f è l'identità. Se consideriamo una funzione tipo 4. e f l'identità otterrei un grafo completo. In questo caso si fissa $\delta > 0$ e $f(z) = \mathbb{1}_{z > \delta}$

11 Vettori aleatori

11.1 Vettori isotropi

Definizione 11.1. Dato un vettore aleatorio X in \mathbb{R}^n definiamo la sua **matrice di covarianza** $\Sigma(X)$ in $\mathbb{R}^{n \times n}$ come

$$\Sigma(X)_{ij} = \mathbb{E}[X_i X_j]$$

Diremo che X è **isotropo** se $\Sigma(X) = I_n$

Lemma 11.1. *Sia X vettore aleatorio isotropo allora*

(i)
$$\forall x \in \mathbb{R}^n \text{ deterministico} \quad \mathbb{E}[\langle X, x \rangle^2] = \|x\|^2$$

(ii)
$$\mathbb{E}[\|X\|^2] = n$$

(iii) *Se Y è vettore aleatorio isotropo e indipendente da X vale*

$$\mathbb{E}[\langle X, Y \rangle^2] = n$$

Dimostrazione.

(i)
$$\begin{aligned} \mathbb{E}[\langle X, x \rangle^2] &= \mathbb{E} \left[\left(\sum_{i=1}^n X_i x_i \right)^2 \right] = \sum_{i=1}^n \sum_{j=1}^n \mathbb{E}[X_i x_i X_j x_j] = \\ &= \sum_{i=1}^n \sum_{j=1}^n x_i x_j \mathbb{E}[X_i X_j] = \sum_{i=1}^n x_i^2 = \|x\|^2 \end{aligned}$$

infatti essendo X isotropo $\mathbb{E}[X_i X_j] = \delta_{ij}$

(ii)
$$\mathbb{E}[\|X\|^2] = \sum_{i=1}^n \mathbb{E}[X_i^2] = n$$

(iii) Usando la proprietà di speranza condizionata

$$\mathbb{E}[\langle X, Y \rangle^2] = \mathbb{E} [\mathbb{E}[\langle X, Y \rangle^2 | Y]] = \mathbb{E}[\|Y\|^2] = n$$

dove $=_1$ deriva dal fatto che X è isotropo per $\mathbb{P}(\cdot | Y)$ infatti essendo $X \perp Y$ otteniamo

$$\mathbb{E}[X_i X_j | Y] = \mathbb{E}[X_i X_j] = \delta_{ij}$$

Definizione 11.2. Diremo che $X \sim Unif(\sqrt{n}S^{n-1})$ se X è un vettore aleatorio con legge proporzionale alla misura di Hausdorff $(n-1)$ -dimensionale su S^{n-1} .

Lemma 11.2. *Valgono i seguenti risultati*

- $X \sim Unif(\sqrt{n}S^{n-1})$ è isotropo.
- Se X_1, \dots, X_n sono v.a. di Rademacher indipendenti allora il vettore $X = (X_1, \dots, X_n)$ è isotropo.

Dimostrazione.

- Poichè la distribuzione è uniforme

$$\mathbb{E}[X_1^2] = \dots \mathbb{E}[X_n^2]$$

e dunque

$$\mathbb{E}[X_i^2] = \frac{1}{n} \mathbb{E} \left[\sum_{j=1}^n X_j^2 \right] = \frac{1}{n} \mathbb{E}[\|X\|^2] = 1$$

infatti $X \in \sqrt{n}S^{n-1}$

$$\mathbb{E}[X_i X_j] = \mathbb{E}[X_i(-X_j)] = -\mathbb{E}[X_i X_j] \quad \Rightarrow \quad \mathbb{E}[X_i X_j] = 0$$

dove abbiamo usato che essendo la distribuzione uniforme, $(X_i, X_j) \sim (X_i, -X_j)$

- $\mathbb{E}[X_i^2] = \mathbb{E}[1] = 1$.
Siano $i \neq j$ allora

$$\mathbb{E}[X_i X_j] = \mathbb{E}[X_i] \mathbb{E}[X_j] = 0$$

essendo le v.a. di Rademacher centrate e indipendenti.

Osservazione 32. Se $O \in O(n)$ e $X \sim \text{Unif}(\sqrt{n}S^{n-1})$ allora $OX \sim \text{Unif}(\sqrt{n}S^{n-1})$

11.2 Vettori e matrici gaussiane

Definizione 11.3. Un vettore aleatorio X è detto **gaussiano** standard se ha entrate i.i.d. normali standard.

Un vettore aleatorio Y è detto gaussiano se $\exists A \in \mathbb{R}^{n \times d}, b \in \mathbb{R}^n$ deterministico e X gaussiano standard d -dimensionale tale che $Y = AX + b$

Proposizione 11.3. Se $Y = AX + b$ è gaussiano allora

$$\mathbb{E}[Y] = b$$

$$\text{Cov}(Y) = AA^T$$

In particolare, un vettore gaussiano standard è isotropo.

Proposizione 11.4. Sia X un vettore gaussiano in \mathbb{R}^n allora la sua funzione generatrice

$$M_X(t) = \exp\left(\langle t, b \rangle + \frac{1}{2}\langle t, \Gamma t \rangle\right)$$

dove

$$b = \mathbb{E}[X] \quad \Gamma = \text{Cov}(X)$$

Osservazione 33. Dal Teorema 1.3, se X e Y sono vettori gaussiani con stessa media e stessa matrice di covarianza, allora $X \sim Y$. Dunque denotiamo la legge di un vettore di media b e covarianza Γ con $\mathcal{N}(b, \Gamma)$.

Proposizione 11.5. Sia Γ invertibile e $X \sim \mathcal{N}(b, \Gamma)$ allora

$$f_X(x) = \frac{1}{(\sqrt{2\pi})^n \sqrt{\det \Gamma}} \exp\left(-\frac{1}{2}\langle (x - b), \Gamma^{-1}(x - b) \rangle\right)$$

Definizione 11.4. Una matrice aleatoria G è detta gaussiana se ha entrate i.i.d. normali standard.

Proposizione 11.6. Sia G una matrice $n \times n$ gaussiana standard. Dette G_1, \dots, G_n le sue colonne si ha

$$\mathbb{P}(G_1, \dots, G_n \text{ base di } \mathbb{R}^n) = 1$$

Dimostrazione. Basta provare che $\mathbb{P}(\det G = 0) = 0$. Ricordiamo che

$$\det G = \sum_{\sigma \in S_n} (-1)^{P(\sigma)} G_{1,\sigma(1)} \cdots G_{n,\sigma(n)} := F((G_{ij})_{i,j=1}^n)$$

Ora poichè

$$\Gamma = \{x = (x_{i,j})_{i=1}^n \mid F(x) = 0\}$$

ha misura di Lebesgue nulla otteniamo la tesi. □

12 Ampiezza sferica e gaussiana

Definizione 12.1. Dato $T \subseteq \mathbb{R}^n$ la sua **ampiezza sferica** è data da

$$w_S(T) = \mathbb{E} \left[\sup_{t \in T} \langle t, \theta \rangle \right]$$

dove $\theta \sim \text{Unif}(S^{n-1})$

Definizione 12.2. Dato $T \subseteq \mathbb{R}^n$ la sua **ampiezza gaussiana** è data da

$$w(T) = \mathbb{E} \left[\sup_{t \in T} \langle t, g \rangle \right]$$

dove $g \sim \mathcal{N}(0, I_n)$

Lemma 12.1. Sia $g \sim \mathcal{N}(0, I_n)$ allora $\frac{g}{\|g\|}$ e $\|g\|$ sono v.a. indipendenti.

Inoltre $\frac{g}{\|g\|} \sim \text{Unif}(S^{n-1})$ mentre $\|g\|$ è una v.a. continua con densità della forma $ce^{-\frac{r^2}{2}} r^{n-1}$

Dimostrazione. Poichè $g \sim \mathcal{N}(0, I_n)$

$$\mathbb{E}[h(G)] = \frac{1}{(\sqrt{2\pi})^n} \int_{\mathbb{R}^n} e^{-\frac{\|x\|^2}{2}} h(x) dx = \frac{1}{(\sqrt{2\pi})^n} \int_{S^{n-1}} ds(\theta) \int_0^{+\infty} dr r^{n-1} e^{-\frac{r^2}{2}} h(r\theta)$$

Calcolando tale valore atteso per $h(g) = h_1\left(\frac{g}{\|g\|}\right) h_2(\|g\|)$ otteniamo la tesi. □

Proposizione 12.2. Sia $T \subseteq \mathbb{R}^n$ allora

$$w(T) = \mathbb{E}[\|g\|_2] w_S(T)$$

dove $g \sim \mathcal{N}(0, I_n)$

Dimostrazione.

$$\begin{aligned} w(T) &= \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle \right] = \mathbb{E} \left[\sup_{t \in T} \left\| \|g\| \frac{g}{\|g\|}, t \right\rangle \right] = \mathbb{E} \left[\|g\| \sup_{t \in T} \left\langle \frac{g}{\|g\|}, t \right\rangle \right] =_1 \\ &= \mathbb{E}[\|g\|] \mathbb{E} \left[\sup_{t \in T} \left\langle \frac{g}{\|g\|}, t \right\rangle \right] =_2 w_S(T) \end{aligned}$$

dove $=_1$ deriva dall'indipendenza delle due v.a. mentre $=_2$ dal fatto che $\frac{g}{\|g\|}$ è uniforme sulla sfera. □

Lemma 12.3. Esiste una costante assoluta C tale che

$$\sqrt{n} - C \leq \mathbb{E}[\|g\|] \leq \sqrt{n}$$

Dimostrazione. Proviamo solo l'upper bound.

$$\mathbb{E}[\|g\|] \leq_{C-S} \mathbb{E}[\|g\|^2]^{\frac{1}{2}} = \mathbb{E} \left[\sum_{i=1}^n g_i^2 \right]^{\frac{1}{2}} = \left(\sum_{i=1}^n \mathbb{E}[g_i^2] \right)^{\frac{1}{2}} \leq \sqrt{n}$$

Proposizione 12.4. Siano $T, S \subseteq \mathbb{R}^n$ allora valgono le seguenti affermazioni

(i) $w(T) \in [0, +\infty]$

(ii) $w(T) \leq \infty \Leftrightarrow T$ limitato

(iii) $\omega(OT + y) = w(T)$ per ogni $O \in O(n)$ e $y \in \mathbb{R}^n$

(iv) $w(T) = w(\text{conv}(T))$

(v) $w(T + S) = w(T) + w(S)$

(vi) $w(aT) + |a|w(T)$ per ogni $a \in \mathbb{R}$

(vii) $\omega(T) = \frac{1}{2}w(T - T)$

(viii) $\frac{1}{\sqrt{2\pi}}\text{diam}(T) \leq w(T) \leq \frac{\sqrt{n}}{2}\text{diam}(T)$

Dimostrazione. Nel seguito della dimostrazione $g \sim \mathcal{N}(0, I_n)$

(i) Sia $t_0 \in T$ allora

$$w(T) = \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle \right] \geq \mathbb{E}[\langle g, t_0 \rangle]$$

Ma poichè $g \sim -g$ otteniamo

$$\mathbb{E}[\langle g, t_0 \rangle] = \mathbb{E}[\langle -g, t_0 \rangle] = -\mathbb{E}[\langle g, t_0 \rangle] = 0$$

(ii) Proviamo solo \Leftarrow . Per C.S. si ha $\langle g, t \rangle \leq \|g\| \|t\|$ e dunque posto $C(T) = \sup \|t\|$ si ha

$$w(T) = \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle \right] \leq C(T) \mathbb{E}[\|g\|] < \infty$$

(iii) Proviamo l'invarianza per l'azione di $O(n)$. Sia $O \in O(n)$ allora

$$w(OT) = \mathbb{E} \left[\sup_{t \in T} \langle g, Ot \rangle \right] = \mathbb{E} \left[\sup_{t \in T} \langle O^T g, t \rangle \right]$$

ora $O^T g \sim g$ e dunque la tesi.

Proviamo l'invarianza per traslazioni

$$w(T + y) = \mathbb{E} \left[\sup_{t \in T} \langle g, t + y \rangle \right] = \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle \right] + \mathbb{E}[\langle g, y \rangle]$$

Ora ripercorrendo quanto fatto nel punto (i) si prova che il secondo addendo è nullo

(iv) Poichè $T \subseteq \text{conv}(T)$ usando la monotonia dell'estremo superiore ho

$$w(T) \leq w(\text{conv}(T))$$

Per l'altra disuguaglianza notiamo che se $\sum \lambda_i = 1$ con $\lambda_i \geq 0$ e $x_1, \dots, x_n \in T$ allora

$$\langle g, \sum_{i=1}^m \lambda_i x_i \rangle = \sum_{i=1}^m \lambda_i \langle g, x_i \rangle \leq \max_i \langle g, x_i \rangle \sum_{i=1}^m \lambda_i = \max_i \langle g, x_i \rangle \leq \sup_{t \in T} \langle g, t \rangle$$

Dunque

$$w(\text{conv}(T)) = \mathbb{E} \left[\sup_{m \geq 1} \sup_{\substack{\lambda_1, \dots, \lambda_m \geq 0 \\ \sum \lambda_i = 1}} \sup_{x_1, \dots, x_m \in T} \langle g, \sum \lambda_i x_i \rangle \right] \leq \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle \right] = w(T)$$

(v)

$$w(T + S) = \mathbb{E} \left[\sup_{\substack{t \in T \\ s \in S}} \langle g, t + s \rangle \right] = \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle + \sup_{s \in S} \langle g, s \rangle \right] = w(T) + w(S)$$

(vi) Sia $a > 0$ allora

$$w(aT) = \mathbb{E} \left[\sup_{t \in T} \langle g, at \rangle \right] = a \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle \right] = aw(T)$$

Il caso $a < 0$ si prova osservando che $g \sim -g$ e dunque $w(T) = w(-T)$

(vii) Segue applicando il punto precedente a $T = T$ e $S = -T$

(viii) Per il punto precedente

$$w(T) = \frac{1}{2} \mathbb{E} \left[\sup_{x, y \in T} \langle g, x - y \rangle \right]$$

Ora se $a, b \in T$ si ha

$$w(T) \geq \frac{1}{2} \mathbb{E} [\max \langle g, a - b \rangle, \langle g, b - a \rangle] = \frac{1}{2} \mathbb{E} [|\langle g, b - a \rangle|]$$

Ma ora

$$\langle g, a - b \rangle = \sum_{i=1}^n g_i (a_i - b_i) \sim \mathcal{N} \left(0, \sum (a_i - b_i)^2 \right) = \mathcal{N} (0, \|a - b\|^2)$$

Abbiamo dunque

$$w(T) \geq \frac{1}{2} \|a - b\| \mathbb{E}[|Z|] \text{ con } Z \sim \mathcal{N}(0, 1)$$

passando al sup in a, b otteniamo l'upper bound.

Per il lower bound

$$w(T) = \frac{1}{2} \mathbb{E} \left[\sup_{x, y \in T} \langle g, x - y \rangle \right] \leq \frac{1}{2} \mathbb{E} \left[\sup_{x, y \in T} \|g\| \|x - y\| \right] \leq \frac{1}{2} \mathbb{E} [\|g\| \text{diam}(T)]$$

Ricordando che $\mathbb{E}[\|g\|] \leq \sqrt{n}$ la tesi

□

Esempio 12.5. *Posta*

$$B_p^n = \left\{ x \in \mathbb{R}^n \mid \|x\|_p = 1 \right\}$$

si ha

$$w(S^{n-1}) = \mathbb{E} \left[\sup_{t \in S^{n-1}} \langle g, t \rangle \right] = \mathbb{E}[\|g\|] \in [\sqrt{n} - C, \sqrt{n}]$$

$$w(B_2^n) = \mathbb{E} \left[\sup_{t \in B_2^n} \langle g, t \rangle \right] = \mathbb{E}[\|g\|_2]$$

$$w(B_\infty^n) = \mathbb{E}[\|g\|_1] = \sqrt{\frac{2}{\pi}} n$$

$$w(B_1^n) = \mathbb{E} \left[\sup_{t \in B_2^n} \langle g, t \rangle \right] = \mathbb{E}[\|g\|_\infty]$$

Osservazione 34. Vale il seguente risultato

$$\exists C_1, C_2 \quad c_1 \sqrt{\log n} \leq \mathbb{E}[\|g\|_\infty] \leq C_2 \log n$$

13 Recovery problem

Andiamo a presentare un problema che va sotto il nome di **recovery**. Supponiamo di disporre di $K \subseteq \mathbb{R}^n$ un insieme limitato e siamo interessati a trovare un certo vettore $x \in K$. Vogliamo trovare x avendo a disposizione solo m osservazioni gaussiane di tipo lineare su x cioè conosco

$$y_1 = \langle a^{(1)}, x \rangle, \dots, y_m = \langle a^{(m)}, x \rangle$$

dove $a^{(1)}, \dots, a^{(m)}$ sono vettori gaussiani standard indipendenti (in senso probabilistico).

Posto $A = \begin{pmatrix} a^{(1)} \\ \vdots \\ a^{(m)} \end{pmatrix}$ io conosco $y = Ax$.

La filosofia è cercare di trovare il minimo valore di m per cui se stimo x con una generica soluzione \hat{x} del sistema

$$\begin{cases} \hat{x} \in K \\ y = A\hat{x} \end{cases} \quad (11)$$

allora x e \hat{x} sono "vicini".

Per formalizzare tale problema occorre introdurre la Grassmanniana

Definizione 13.1. Siano $1 \leq m \leq n$ allora la **varietà grasmaniana** $G_{n,m}$ è la famiglia dei sottospazi m -dimensionale di \mathbb{R}^n . Definiamo su $G_{n,m}$ la metrica

$$d(E, F) = \|P_E - P_F\|$$

dove $\|\cdot\|$ è la norma operatoriale per operatori lineari e P_E è la proiezione ortogonale su E .

Definizione 13.2. Una distribuzione è detta uniforme su $G_{n,m}$ se la sua legge è invariante sotto l'azione del gruppo ortogonale

Lemma 13.1. Sia $n \geq m$ e $A \in \mathbb{R}^{n \times m}$ una matrice gaussiana standard. Allora

$$Ker A \sim Unif(G_{n,n-m})$$

Dimostrazione. Poniamo $A' = (A^1 \ \dots \ A^m)$ dove A^i è la i -esima colonna di A , allora A' è una matrice gaussiana standard $m \times m$ e quindi per la Proposizione 11.6 è quasi certamente invertibile. $rank(A) = m$ e dunque $\dim Ker A = n - m$. Abbiamo dunque provato $Ker(A) \in G_{n,n-m}$. Per concludere basta provare che $OKer(A) \sim Ker(A)$ per ogni $O \in O(n)$.

$$\begin{aligned} y \in Ker A &\Rightarrow Ay = 0 \Rightarrow AO^T Oy = 0 \Rightarrow Oy \in Ker(AO^T) \\ y \in Ker(AO^T) &\Rightarrow AO^T y = 0 \Rightarrow O^T y \in Ker A \Rightarrow y = O(O^T y) \in OKer(A) \end{aligned}$$

Le implicazioni precedenti provano che $OKer(A) = Ker(AO^T) \sim Ker(A)$ infatti $A \sim AO^T$. \square

Teorema 13.2 (M^* -bound). Sia $K \subseteq \mathbb{R}^n$ limitato e sia $1 \leq m \leq n$. Se $E \sim Unif(G_{n,n-m})$ allora

$$\mathbb{E}[diam(K \cap E)] \leq C_0 \frac{w(K)}{\sqrt{n}}$$

dove $C_0 = 2\sqrt{2\pi}$

Teorema 13.3 (Estimation from gaussian linear observation-feasability problem). *Sia $1 \leq m \leq n$ e $K \subseteq \mathbb{R}^m$ limitato. Sia $A \in \mathbb{R}^{m \times n}$ una matrice gaussiana standard. Se $\hat{x}, x \in K$ tali che $A\hat{x} = Ax$ allora*

$$\mathbb{E} [\|x - \hat{x}\|_2] \leq 2C_0 \frac{w(K)}{\sqrt{n}}$$

dove $C_0 = 2\sqrt{2\pi}$

Dimostrazione. Applicando M^* -bound rimpiazzando K con $K - K$ ottengo

$$\mathbb{E} [\text{diam}((K - K) \cap E)] \leq C_0 \frac{w(K - K)}{\sqrt{n}} = 2C_0 \frac{w(K)}{\sqrt{n}} \quad (12)$$

dove $E = \text{Ker}A \sim \text{Unif}(G_{n,n-m})$ Ora poichè $x, \hat{x} \in K$ si ha $x - \hat{x} \in K - K$ e poichè $Ax = A\hat{x}$ si ha $x - \hat{x} \in \text{Ker}A = E$. Notando che anche $0 \in (K - K) \cap E$ otteniamo

$$\|x - \hat{x}\|_2 = \|(x - \hat{x}) - 0\|_2 \leq \text{diam}((K - K) \cap E)$$

Prendendo il valore atteso in entrambi i membri ed utilizzando (12) la tesi. □

Osservazione 35. Se voglio che l'errore in media sia più piccolo di δ , basta prendere

$$m \geq \frac{C_0^2}{4\delta^2} w(K)^2$$

ovvero l'ordine dell' m ottimale è lo stesso ordine di $w(K)^2$

Osservazione 36. Se K è convesso, noti (K, A, y) la soluzione del sistema (11) è numericamente migliore rispetto al caso non convesso.

Poichè sappiamo che $w(K) = w(\text{conv}(K))$ e $x \in K \subseteq \text{conv}(K)$ posso applicare la teoria sostituendo a K il suo involucro convesso senza peggiorare le stime

13.1 Recovery problem con rumore

Considereremo un problema simile al caso precedente ma supporremo che le m misurazioni gaussiane siano affette da rumore.

Teorema 13.4 (M^* -bound generalizzato). *Sia $T \subseteq \mathbb{R}^n$ limitato e $A \in \mathbb{R}^{m \times n}$ matrice gaussiana standard. Fissato $\varepsilon > 0$ poniamo*

$$T_\varepsilon = \left\{ t \in T \mid \frac{1}{m} \|At\|_{L^1} \leq \varepsilon \right\}$$

allora vale

$$\mathbb{E} \left[\sup_{t \in T_\varepsilon} \|t\|_2 \right] \leq \sqrt{\frac{8\pi}{m}} \mathbb{E} \left[\sup_{t \in T} |\langle g, t \rangle| \right] + \varepsilon \sqrt{\frac{\pi}{2}}$$

Proposizione 13.5. *Il Teorema precedente generalizza l' M^* -bound*

Dimostrazione. Si applichi M^* -bound generalizzato sostituendo T con $T - T$ e con $\varepsilon = 0$. Allora

$$T_0 = \{t \in T - T \mid \|At\|_{L^1} = 0\} = (T - T) \cap \text{Ker}A \supseteq (T \cap \text{Ker}A) - (T \cap \text{Ker}A)$$

dove per l'ultima inclusione abbiamo usato che $Ker A$ è chiuso per differenze.

Allora

$$\mathbb{E} \left[\sup_{t \in T_0} \|t\| \right] \geq \mathbb{E} \left[\sup_{t, t' \in T \cap Ker A} \|t - t'\| \right] = \mathbb{E} [diam(T \cap Ker A)]$$

Notando che

$$\mathbb{E} \left[\sup_{t \in T-T} |\langle g, t \rangle| \right] = \mathbb{E} \left[\sup_{t \in T-T} \langle g, t \rangle \right] = w(T - T) = 2w(T)$$

si ha la tesi. □

Teorema 13.6 (Feasibility problem con rumore). *Sia $K \subseteq \mathbb{R}^n$ limitato, $A \in \mathbb{R}^{m \times n}$ gaussiana standard, $\varepsilon > 0$ fissato e $\mu \in \mathbb{R}^m$ tale che $\frac{1}{m} \|\mu\|_{L^1} \leq \varepsilon$. Sia $x \in K$ e $y = Ax + \mu$ allora preso $\hat{x} \in K$ con $\frac{1}{m} \|A\hat{x} - y\|_{L^1} \leq \varepsilon$ vale*

$$\mathbb{E} [\|x - \hat{x}\|] \leq 4\sqrt{2\pi} \frac{w(K)}{\sqrt{m}} + \varepsilon\sqrt{2\pi}$$

Dimostrazione. Applicando M^* -bound generalizzato con $T = K - K$ e sostituendo ε con 2ε si che

$$\mathbb{E} \left[\sup_{t \in T_{2\varepsilon}} \|t\| \right] \leq \sqrt{\frac{8\pi}{m}} \mathbb{E} \left[\sup_{t \in K-K} |\langle g, t \rangle| \right] + \varepsilon\sqrt{2\pi}$$

Ora con considerazioni simili a quelle usate nella dimostrazione della Proposizione precedente si ha $\mathbb{E} [\sup_{t \in K-K} |\langle g, t \rangle|] = 2w(T)$ e la tesi segue provando che $x - \hat{x} \in T_{2\varepsilon}$ infatti

$$\frac{1}{m} \|Ax - A\hat{x}\|_{L^1} = \frac{1}{m} \|y - \mu - A\hat{x}\|_{L^1} \leq \frac{1}{m} \|y - A\hat{x}\|_{L^1} + \frac{1}{m} \|\mu\|_{L^1} \leq 2\varepsilon$$

□

14 Compressione di dati

Prima di enunciare il Lemma di Johnson-Linderstrauss, alla base dell'algorithmo di compressione illustrato in questa sezione, occorre presentare alcuni risultati preliminari

Teorema 14.1 (di concentrazione per funzioni Lipschitziane sulla sfera). *Sia $X \sim Unif(\sqrt{n}S^{n-1})$ e $f : \sqrt{n}S^{n-1} \rightarrow \mathbb{R}$ una funzione lipschitziana.*

(i)

$$\|f(X) - \mathbb{E}[f(X)]\|_{\psi_2} \leq C \|f\|_{Lip}$$

(ii) *Se, inoltre, $p > 0$ e $f \geq 0$ allora*

$$\|f(X) - \|f(X)\|_{L^p}\|_{\psi_2} \leq C(p) \|f\|_{Lip}$$

con $C(p)$ indipendente da f .

dove $\|f\|_{Lip}$ è la migliore costante $c = c(f)$ tale che $|f(x) - f(y)| \leq c \|x - y\|$

Dimostrazione. Non dimostriamo il primo punto, osserviamo solamente che essendo la funzione f lipschitziana e la sfera compatti, la funzione f è limitata e quindi integrabile.

Proviamo (ii). Dalla disuguaglianza triangolare e dal punto (i) si ha

$$\begin{aligned} \|f(X) - \|f(X)\|_{L^p}\|_{\psi_2} &\leq \|f(X) - \mathbb{E}[f(X)]\|_{\psi_2} + \|\mathbb{E}[f(X)] - \|f(X)\|_{L^p}\|_{\psi_2} \leq \\ &\leq C \|f\|_{Lip} + |\mathbb{E}[f(X)] - \|f(X)\|_{L^p}| \|1\|_{\psi_2} \end{aligned}$$

Ora poichè $f \geq 0$ allora $\|\mathbb{E}[f(X)]\|_{L^p} = |\mathbb{E}[f(X)]| = \mathbb{E}[f(X)]$ e quindi

$$|\mathbb{E}[f(X)] - \|f(X)\|_{L^p}| = |\|\mathbb{E}[f(X)]\|_{L^p} - \|f(X)\|_{L^p}| \leq \|\mathbb{E}[f(X)] - f(X)\|_{L^p}$$

Ora usando l'Osservazione 24 si ha

$$\|f(X) - \mathbb{E}[f(X)]\|_{L^p} \leq C\sqrt{p} \|f(X) - \mathbb{E}[f(X)]\|_{\psi_2} \leq C\sqrt{p} \|f\|_{Lip}$$

da cui la tesi

Possiamo riformulare il Teorema precedente per $X \sim Unif(S^{n-1})$ e otteniamo la

Proposizione 14.2. *Sia $X \sim Unif(S^{n-1})$ e $f : S^{n-1} \rightarrow \mathbb{R}$ una funzione lipschitziana. Allora*

$$\|f(X) - \mathbb{E}[f(X)]\|_{\psi_2} \leq \frac{C}{\sqrt{n}} \|f\|_{Lip} \quad (13)$$

Inoltre se $f \geq 0$ vale

$$\|f(X) - \|f(X)\|_{L^p}\|_{\psi_2} \leq \frac{C(p)}{\sqrt{n}} \|f\|_{Lip} \quad (14)$$

Dimostrazione. Sia

$$g : \sqrt{n}S^{n-1} \rightarrow \mathbb{R} \quad g(x) = f\left(\frac{x}{\sqrt{n}}\right)$$

allora g è lipschitziana e vale $\|g\|_{Lip} = \frac{\|f\|_{Lip}}{\sqrt{n}}$. Poniamo $Y = \sqrt{n}X$ si ha $Y \sim Unif(\sqrt{n}S^{n-1})$ e $f(X) = g(Y)$. Applicando i due risultati a g la tesi segue.

□

Osservazione 37 (Chiave per il Lemma successivo). Sia $z \in S^{n-1}$ e sia $\tilde{P} : \mathbb{R}^n \rightarrow \mathbb{R}^m$ la proiezione sulle prime m componenti. Se $Z \sim \text{Unif}(S^{n-1})$ allora

$$\|Pz\| \sim \|\tilde{P}Z\|$$

Lemma 14.3. *Sia ε e $P = P_E$ con $E \sim \text{Unif}(G_{n,m})$. Fissato $z \in \mathbb{R}^n$ vale*

(i)

$$\mathbb{E} [\|Pz\|^2]^{\frac{1}{2}} = \sqrt{\frac{m}{n}} \|z\|$$

(ii) con probabilità $\geq 1 - 2 \exp(-c\varepsilon^2 m)$ si ha

$$(1 - \varepsilon) \sqrt{\frac{m}{n}} \|z\| \leq \|Pz\| \leq (1 + \varepsilon) \sqrt{\frac{m}{n}} \|z\| \quad (15)$$

Dimostrazione. Per omogeneità basta provare la tesi per $z \in S^{n-1}$.

(i) Usando l'Osservazione precedente,

$$\mathbb{E} [\|\tilde{P}Z\|^2] = \mathbb{E} [Z_1^2 + \dots + Z_m^2] = m\mathbb{E}[Z_1^2]$$

ma

$$1 = \mathbb{E} [\|Z\|^2] = \mathbb{E} [Z_1^2 + \dots + Z_n^2] = n\mathbb{E} [Z_1^2]$$

da cui la tesi

(ii) La funzione

$$f : S^{n-1} \rightarrow \mathbb{R} \quad f(x) = \|(x_1, \dots, x_m)\|$$

è lipschitziana con $\|f\|_{Lip} = 1$, usando (14) e l'Osservazione 24 otteniamo che esiste una costante universale C_1 con

$$\mathbb{P} (|f(Z) - \|f(Z)\|_{L^2}| \geq t) \leq 2 \exp(-C_1 n t^2)$$

ma $f(Z) = \|\tilde{P}Z\|$ e $\|f(Z)\|_{L^2} = \sqrt{\frac{m}{n}}$.

Prendendo $t = \varepsilon \sqrt{\frac{m}{n}}$ si ha la tesi

□

Teorema 14.4 (Lemma di Johnson-Linderstrauss). *Sia $\chi \subseteq \mathbb{R}^n$ di cardinalità N e $\varepsilon > 0$. Sia inoltre $m \in \mathbb{N}$ tale che*

$$n \geq m \geq \frac{C}{\varepsilon^2} \log N$$

Sia $E \sim \text{Unif}(G_{n,m})$ e posta $Q = \sqrt{\frac{n}{m}} P_E$ con P_E proiezione ortogonale su E , con probabilità di almeno $1 - 2 \exp(-c\varepsilon^2 m)$ vale

$$(1 - \varepsilon) \|x - y\| \leq \|Qx - Qy\| \leq (1 + \varepsilon) \|x - y\|$$

dove C, c sono costanti assolute positive.

Dimostrazione. Dalla definizione di Q , posso riscrivere (15) come

$$(1 - \varepsilon) \|z\| \leq \|Qz\| \leq (1 + \varepsilon) \|z\| \quad (16)$$

Ora

$$\begin{aligned} \mathbb{P}((16) \text{ non valga } \forall z = x - y \text{ con } x, y \in \chi) &\leq \sum_{x, y \in \chi} \mathbb{P}((16) \text{ non valga per } z = x - y) = \\ &= N^2 2 \exp(-c\varepsilon^2 m) = 2 \exp(2 \log N - c\varepsilon^2 m) \leq 2 \exp\left(2m \frac{\varepsilon^2}{C} - c\varepsilon^2 m\right) = \\ &= 2 \exp\left(-\varepsilon^2 m \left(c - \frac{2}{C}\right)\right) \end{aligned}$$

prendendo $\frac{2}{C} = \frac{c}{2}$ si ha

$$\mathbb{P}((16) \text{ non valga } \forall z = x - y \text{ con } x, y \in \chi) \leq 2 \exp\left(-\varepsilon^2 m \frac{c}{2}\right)$$

Ora rinominando $\frac{c}{2}$ con c e passando al complementare otteniamo la tesi. □

Osservazione 38. Per generare $E \sim Unif(G_{n,m})$ basta prendere $E = \text{span}(v_1, \dots, v_m)$ dove v_1, \dots, v_m sono i.i.d. gaussiani standard

Osservazione 39. $Q(\chi)$ è uno spazio m -dimensionale: invece di memorizzare χ (quindi nN entrate), memorizzo $Q(\chi)$ (quindi mN)

15 Esercizi

Esercizio 15.1. Sia $K = [0, a]$ con $a > 0$ dotato della distanza euclidea. Calcolare il suo numero di ricoprimento e impacchettamento.

Dimostrazione. L'intuizione geometrica ci suggerisce che

$$N(k, d, \varepsilon) = \lceil \frac{a}{2\varepsilon} \rceil$$

Un ε -net con tale cardinalità esiste (si prendono i punti $\varepsilon, 3\varepsilon, \dots$ e se a non è un multiplo di 2ε prendiamo anche a), proviamo che non ne possono esistere di cardinalità minore.

Sia A un ε -net di K allora

$$K \subseteq \bigcup_{x \in A} [x - \varepsilon, x + \varepsilon] \Rightarrow l(K) \leq l\left(\bigcup_{x \in A} [x - \varepsilon, x + \varepsilon]\right) \leq \sum_{x \in A} l([x - \varepsilon, x + \varepsilon]) \leq 2\varepsilon |A|$$

Da cui $|A| \geq \frac{a}{2\varepsilon}$ e poichè la cardinalità è un numero naturale, possiamo prendere la parte intera superiore.

Sia $A \subseteq [0, a]$ un insieme ε -separato di cardinalità n . Allora poichè ogni punto deve essere a distanza ε si ha

$$(n - 1)\varepsilon < a \Rightarrow n < \frac{a}{\varepsilon} + 1 \quad (17)$$

Andiamo a distinguere due differenti casi

- Se a è un multiplo di ε allora la disuguaglianza (17) diventa $n \leq \frac{a}{\varepsilon}$.

Siano

$$x_k = k(\varepsilon + \delta) \quad \text{con } k = 0, 1, \dots, \frac{a}{\varepsilon} - 1 \text{ e } \delta > 0 \text{ piccolo}$$

Allora $\{x_k\}$ è un ε -separato di cardinalità massima. Il numero d'impacchettamento vale $\frac{a}{\varepsilon}$

- Supponiamo che a non sia un multiplo di ε . Essendo la cardinalità un numero naturale, la disuguaglianza (17) diventa $n \leq \lfloor \frac{a}{\varepsilon} \rfloor + 1$. Se prendiamo

$$x_k = k(\varepsilon + \delta) \quad \text{con } k = 0, 1, \dots, \frac{a}{\varepsilon} \text{ e } \delta > 0 \text{ piccolo}$$

otteniamo che $\{x_k\}$ è un insieme ε -separato massimale e dunque il numero d'impacchettamento vale $\lfloor \frac{a}{\varepsilon} \rfloor + 1$

Esercizio 15.2.

- Supponiamo che la distanza su T sia indotta da una norma allora

$$d(x, y) \leq \varepsilon \Leftrightarrow B\left(x, \frac{\varepsilon}{2}\right) \cap B\left(y, \frac{\varepsilon}{2}\right) \neq \emptyset$$

- Se la distanza non è indotta da una norma vale solamente una delle due implicazioni

Dimostrazione.

- \Leftarrow Sia $z \in B\left(x, \frac{\varepsilon}{2}\right) \cap B\left(y, \frac{\varepsilon}{2}\right)$ allora

$$d(x, y) \leq d(x, z) + d(z, y) \leq \frac{\varepsilon}{2} + \frac{\varepsilon}{2} = \varepsilon$$

Si noti che non abbiamo usato nessuna proprietà dedotta dalla norma

- \Rightarrow Poniamo $z = \frac{x+y}{2}$ allora

$$d(x, z) = \|x - z\| = \left\| x - \frac{x+y}{2} \right\| = \frac{\|x\| - y}{2} \leq \varepsilon/2$$

e similmente con y . Dunque z appartiene all'intersezione delle due palle.

Come controesempio possiamo prendere $\varepsilon = 1$ con K qualsiasi dotato della metrica discreta:

$$d(x, y) = \begin{cases} 1 & \text{se } x \neq y \\ 0 & \text{se } x = y \end{cases}$$

Esercizio 15.3.

- *Mostrare che non vale l'implicazione*

$$K \subseteq L \quad \Rightarrow \quad N(K, d, \varepsilon) \leq N(L, d, \varepsilon)$$

- *Mostrare che vale l'implicazione*

$$K \subseteq L \quad \Rightarrow \quad P(K, d, \varepsilon) \leq P(L, d, \varepsilon)$$

Dimostrazione.

- Consideriamo i sottoinsiemi di \mathbb{R} : $K_1 = \{-1, 1\}$ e $K_2 = \{-1, 0, 1\}$.
Chiaramente $N(K_1, 1) = 2$ infatti un 1-net deve essere formato da punti dello spazio. Ora una palla centrata in un punto di raggio 1 non contiene l'altro punto (sono a distanza 2). L'insieme $\{0\}$ è un 1-net per K_2 dunque $N(K_2, 1) \leq 1$ e dunque $N(K_2, 1) = 1$ essendo $N(K, 1) \geq 1$ per qualsiasi K .
- L'implicazione segue ricordando la definizione di P e notando che ogni ε -separato per K è un ε -separato per L .

□

Esercizio 15.4. Verificare che nel Teorema di Glivenko-Cantelli valga

$$\mathbb{F}_n(t) - F(t) \geq \mathbb{F}_n(t_{i-1}) - F(t_{i-1}) - \varepsilon \text{ se } t_{i-1} \leq t < t_i$$

Dimostrazione. Si usa che \mathbb{F}_n e F sono funzioni crescenti con limite a sinistra e dunque

$$\mathbb{F}_n(t) - F(t) \geq \mathbb{F}_n(t_{i-1}) - F(t_i^-)$$

si conclude ricordando le proprietà della partizione (t_i) .

□

Esercizio 15.5. *Supponendo che osservando il campione aleatorio X_1, \dots, X_{100} rileviamo i seguenti valori $-2, 5, 8, 3$ con frequenza $20, 25, 40, 15$. Determinare la misura empirica e la funzione di ripartizione empirica associate a tale realizzazione.*

Dimostrazione. Dalla definizione di misura empirica si ha

$$\mathbb{P}_n = \frac{1}{100} (20\delta_{-2} + 15\delta_3 + 25\delta_5 + 40\delta_8)$$

e poichè $\mathbb{F}_n(t) = \mathbb{P}_n((-\infty, t])$ si ha

$$\mathbb{F}_n(t) = \begin{cases} 0 & \text{se } t < -2 \\ \frac{20}{100} & \text{se } -2 \leq t < 3 \\ \frac{35}{100} & \text{se } 3 \leq t < 5 \\ \frac{60}{100} & \text{se } 5 \leq t < 8 \\ 1 & \text{se } t \geq 8 \end{cases}$$

Esercizio 15.6. Consideriamo un campione aleatorio $(X_i)_{i=1}^n$ di v.a. reali (non conosciamo la distribuzione della popolazione). Usando la disuguaglianza DKW determinare di quale ampiezza n dobbiamo prendere il campione affinché, con probabilità almeno 90%, la funzione di ripartizione empirica differisca in norma uniforme al più 0.05 dalla funzione di ripartizione della distribuzione della popolazione.

Dimostrazione. L'esercizio ci chiede di trovare n minimale affinché valga

$$\mathbb{P}(\|\mathbb{F}_n - F\|_\infty \leq 0.05) \geq 0.9$$

Dimostrazione. La tesi equivale a provare che

$$\mathbb{P}(\|\mathbb{F}_n - F\|_\infty > 0.05) \geq 0.1$$

Se troviamo n e x tali che

$$2e^{-2x^2} = 0.10 \quad \frac{x}{\sqrt{n}} = \frac{1}{20}$$

otteniamo la tesi.

Svolgendo i conti otteniamo che n deve essere almeno 600

Esercizio 15.7. Sia $\mathcal{A}_1 = \{G \in \mathcal{A} \mid \int |t| dG(t) < \infty\}$ allora il funzionale

$$\gamma : \mathcal{A}_1 \rightarrow \mathbb{R} \quad \gamma(G) = \int t dG(t)$$

non è continua.

La funzione diventa continua se restringiamo il dominio a $\mathcal{A}_0 = \{G[a, b] \rightarrow [0, 1]\} \cap \mathcal{A}$

Dimostrazione. Sia

$$X_n = \begin{cases} 0 & \text{con probabilità } 1 - \frac{1}{n} \\ n^2 & \text{con probabilità } \frac{1}{n} \end{cases}$$

e G_n la sua funzione di ripartizione. Allora

$$\gamma(G_n) = \mathbb{E}[G_n] = n^2 \frac{1}{n} = n \rightarrow +\infty$$

Notiamo però che posta

$$G(t) = \begin{cases} 0 & \text{se } t < 0 \\ 1 & \text{se } t \geq 0 \end{cases}$$

si ha $G \in \mathcal{A}$ ($dG = \delta_0$) e $\|G - G_n\|_\infty \rightarrow 0$.

Il secondo punto si fa utilizzando la definizione di integrale di Stines(??)

$$\int_a^b t dG(t) = \lim_{n \rightarrow +\infty} \sum_{k=0}^n \left(a + \frac{k}{n}\right) \left(G\left(a + \frac{k}{n}\right) - G\left(a + \frac{k-1}{n}\right)\right) = \dots = bG(b) - \int_a^b G(t) dt$$

Esercizio 15.8. Tale esercizio consiste nel dimostrare il seguente

Lemma 15.1. Sia $\mathcal{G} = \{g : \chi \rightarrow \mathbb{R}\}$ e X una v.a. a valori in χ

$$\sup_{g \in \mathcal{G}} \mathbb{E}[g(X)] \leq \mathbb{E} \left[\sup_{g \in \mathcal{G}} |g(X)| \right]$$

Dimostrazione. Sia $g \in \mathcal{G}$ allora vale

$$g \leq \sup_{f \in \mathcal{G}} |g|$$

infatti $g \leq |g|$ e $g \in \mathcal{G}$. Applicando il valore atteso otteniamo

$$\mathbb{E}[g(X)] \leq \mathbb{E} \left[\sup_{f \in \mathcal{G}} |f|(X) \right]$$

Applicando l'estremo superiore per $g \in \mathcal{G}$ a sinistra otteniamo la tesi □

Esercizio 15.9. Supponiamo che P_X sia senza atomi. Dimostrare che la complessità di Rademacher della classe $\mathcal{S} = \{1_S \mid S \text{ finito}\}$ è maggiore di $\frac{1}{2}$.

Dimostrazione. Poichè P_X non ha atomi allora con probabilità 1, un campione X_1, \dots, X_n ha elementi distinti. Fissata un'estrazione e dati $\varepsilon_1, \dots, \varepsilon_n$ allora

- Se nelle v.a. di Rademacher +1 ha maggior frequenza, l'insieme che massimizza è

$$S = \{X_i \mid \varepsilon_i = 1\}$$

allora

$$\frac{1}{n} \sum \varepsilon_i 1_S(X_i) = \frac{|\{i \mid \varepsilon_i = 1\}|}{n} \geq \frac{1}{2} \cdot \frac{n}{2} = \frac{1}{2}$$

- Se nelle v.a. di Rademacher -1 ha maggior frequenza, l'insieme che massimizza è

$$S = \{X_i \mid \varepsilon_i = -1\}$$

allora

$$\left| \frac{1}{n} \sum \varepsilon_i 1_S(X_i) \right| = \frac{|\{i \mid \varepsilon_i = -1\}|}{n} \geq \frac{1}{2} \cdot \frac{n}{2} = \frac{1}{2}$$

□

Esercizio 15.10. Calcolare la complessità di Rademacher dell'insieme

$$A = \{(2, 3, -1), (1, 1, 0), (3, -2, 1)\}$$

Dimostrazione. Ricordiamo che $R_3(A) = \mathbb{E}[Z_A]$ con $Z_A = \sup_{a \in A} |\langle a, \varepsilon \rangle|$.

Notiamo che

$(\varepsilon_1, \varepsilon_2, \varepsilon_3)$	$ \langle a_1, \varepsilon \rangle $	$ \langle a_2, \varepsilon \rangle $	$ \langle a_3, \varepsilon \rangle $	Z_A
(1, 1, 1)	4	4	2	4
(1, 1, -1)	6	2	0	6
(1, -1, 1)	2	0	6	6
(1, -1, -1)	1	0	4	4

e sfruttando la simmetria otteniamo che

$$\mathbb{E}[Z_A] = \frac{1}{8} \sum_{\varepsilon_1=\pm 1} \sum_{\varepsilon_2=\pm 1} \sum_{\varepsilon_3=\pm 1} Z_A(\varepsilon_1, \varepsilon_2, \varepsilon_3) = \frac{1}{8} \cdot 2(4 + 6 + 6 + 4) = 5$$

□

Esercizio 15.11. Calcolare la dimensione VC delle seguenti classi

- Coppie di intervalli in \mathbb{R}
- Cerchi in \mathbb{R}^2
- Rettangoli in \mathbb{R}^2

Dimostrazione.

- Si prova con una semplice verifica che 4 punti sono sempre frantumati. Mentre se un insieme contiene 5 punti non può essere frantumato. Sia $\Lambda \supseteq \{x_1 < \dots < x_5\}$ allora la funzione

$$f(x_1) = f(x_3) = f(x_5) = 1 \text{ e } f(x_2) = f(x_4) = 0$$

non si può realizzare come restrizione di una funzione caratteristica di due intervalli.

- Si prova con una semplice verifica che 3 punti disposti ai vertici di un triangolo equilatero sono frantumati. Proviamo che un insieme di 4 punti non è mai frantumato. Siano $\Lambda = \{a, b, c, d\} \subseteq \mathbb{R}^2$ un insieme di cardinalità 4 e poniamo

$$m = \min \{|A| \mid A \subseteq \Lambda \quad \Lambda \subseteq \text{conv}(A)\}$$

dove $\text{conv}(A)$ è il più piccolo convesso che contiene A

- $m \neq 1$. Infatti se, per assurdo, $m = 1$ si avrebbe, ad esempio, $\Lambda \subseteq \text{conv}(\{a\}) = \{a\}$ e dunque Λ consterebbe di un solo punto.
- $m = 2$. In questo caso i punti sono allineati e possiamo identificare Λ come un sottoinsieme di \mathbb{R} e assumendo $a < b < c < d$ la funzione

$$f(a) = f(d) = 1 \quad f(b) = f(c) = 0$$

non si realizza come restrizione di indicatori di cerchi (se esistesse si avrebbe $a, d \in C$ cerchio e dunque per convessità anche $b \in C$)

- $m = 3$. Possiamo assumere, senza perdita di generalità che a, b, c siano tre vertici di un triangolo (non degenere) e $d \in \text{conv}(\{a, b, c\})$. Dalla convessità dei cerchi la funzione

$$f(a) = f(b) = f(c) = 1 \quad f(d) = 0$$

non si può realizzare come restrizione di un'indicatrice di un cerchio.

- $m = 4$. I quattro punti sono i vertici di un quadrilatero (non degenere). Se chiamo $\alpha, \beta, \gamma, \delta$ gli angoli rispettivamente in a, b, c, d si ottiene

$$\alpha + \beta + \gamma + \delta = 360^\circ$$

dunque posso assumere, a meno di permutare gli indici, che $\alpha + \gamma \leq 180^\circ$. Proviamo che la funzione

$$f(a) = f(c) = 1 \quad f(b) = f(d)$$

non può essere indotta dall'indicatrice di un cerchio.

Supponiamo per assurdo che esista un cerchio C tale che $a, c \in C$ e $b, d \notin C$. Consideriamo il quadrilatero a', b, c', d' il quadrilatero che si ottiene spostando i vertici a, c lungo ac in modo che $a', c' \in \partial C$.

Poichè $a, c \in C$, se chiamiamo $\alpha', \beta', \delta', \gamma'$ gli angoli del nuovo quadrilatero si ottiene

$$\alpha' \leq \alpha \quad \gamma' \leq \gamma$$

Siano $b', d' \in \partial C$ i punti che si ottengono spostando b, d lungo bd e chiamiamo $\alpha'', \beta'', \gamma'', \delta''$ gli angoli di a', b', c', d' allora poichè $b, d \notin C$ si ottiene

$$\alpha'' < \alpha' \quad \gamma'' < \gamma'$$

Ora essendo a', b', c', d' iscritto in una circonferenza deve accadere che

$$\alpha'' + \gamma'' = 180^\circ$$

Il che è assurdo poichè

$$\alpha'' + \gamma'' < \alpha + \gamma \leq 180^\circ$$

- La dimensione VC è 4 (banale verifica)

Esercizio 15.12. Sia $\mathcal{F} = \{1_S \mid S \subseteq \mathbb{R}^2 \text{ cerchio}\}$.

Trovare $n \in \mathbb{N}$ tale che

$$\mathbb{P}(\|\mathbb{P}_n - P_X\|_{\mathcal{F}} < 0.5) \geq 0.90$$

Come cambia tale n se si vuole uno scarto minore di 0.2.

Si assuma che le costanti assolute valgano tutte e^2 .

Dimostrazione. Poichè $VC(\mathcal{F}) = 3$ dalla Proposizione 5.4

$$\mathbb{P}\left(\|\mathbb{P}_n - P_X\|_{\mathcal{F}} < 2c\sqrt{\frac{VC(\mathcal{F})}{n}} + \delta\right) \geq 1 - 2\exp\left(-\frac{\delta^2 n}{2}\right)$$

e dunque specializzando al nostro caso si ha

$$\mathbb{P}\left(\|\mathbb{P}_n - P_X\|_{\mathcal{F}} < 2e^2\sqrt{\frac{3}{n}} + \delta\right) \geq 1 - 2\exp\left(-\frac{\delta^2 n}{2}\right)$$

Ora imponendo che

$$1 - 2\exp\left(-\frac{\delta^2 n}{2}\right) > 0.9$$

$$2e^2\sqrt{\frac{3}{n}} + \delta \leq 0.5$$

si ottiene che il miglior $n \in \mathbb{N}$ è 3146.

Esercizio 15.13. Siamo interessati a risolvere tramite apprendimento statistico un problema di classificazione. Disponiamo di un campione casuale composto da variabili aleatorie a valori nell'intervallo $[0, 1]$. Supponiamo di usare come spazio ipotesi F le funzioni caratteristiche di intervalli $[a, b]$. Descrivere il protocollo per approssimare con qualche funzione in F la funzione target determinando quanto grande deve essere il campione per avere

- Un rischio eccessivo non superiore a 0.3 con probabilit'a almeno del 70%
- Un valore atteso di rischio eccessivo non superiore a 0.3

Eventuali costanti assolute devono essere poste pari a 2).

Dimostrazione. Dalla Proposizione 6.2 si ha

$$R(f_n^*) - R(f^*) \leq 2 \|\mathbb{P}_n - P\|_{\mathcal{L}}$$

ed inoltre utilizzando il Teorema 5.5 e la Proposizione 6.3 otteniamo

$$R_n(\mathcal{L}) \leq R_n(\mathcal{F}) + \frac{1}{\sqrt{n}} \leq 2C \sqrt{\frac{VC(\mathcal{F})}{n}} + \frac{1}{\sqrt{n}}$$

Ora la dimensione VC della classe degli intervalli vale 1, usando il Teorema 4.5 otteniamo

$$\mathbb{P} \left(\|\mathbb{P}_n - P\|_{\mathcal{L}} < \delta + \frac{2C+1}{\sqrt{n}} \right) \geq 1 - 2 \exp \left(-\frac{n\delta^2}{2} \right)$$

Dunque

$$\mathbb{P} \left(R(f_n^*) - R(f^*) < 2\delta + 2\frac{2C+1}{\sqrt{n}} \right) \geq \mathbb{P} \left(\|\mathbb{P}_n - P\|_{\mathcal{L}} < \delta + \frac{2C+1}{\sqrt{n}} \right) \geq 1 - 2 \exp \left(-\frac{n\delta^2}{2} \right)$$

Dunque per risolvere l'esercizio basta

$$\begin{cases} 1 - 2 \exp \left(-\frac{n\delta^2}{2} \right) \geq 0.7 \\ 2\delta + 2\frac{2C+1}{\sqrt{n}} \leq 0.3 \end{cases} \Rightarrow \begin{cases} \delta \geq \sqrt{-\frac{2 \ln(0.15)}{n}} \\ 2\sqrt{-\frac{2 \ln(0.15)}{n}} + 2\frac{2C+1}{\sqrt{n}} \leq 0.3 \end{cases} \Rightarrow n \geq \frac{(\sqrt{-2 \ln(0.15)} + 5)^2}{18}$$

Esercizio 15.14. Sia X v.a. gaussiana standard. Calcolare $E[e^{cX^2}]$ con $c \in \mathbb{R}$. Usare il risultato ottenuto per verificare direttamente le proprietà (iii) e (iv) della Proposizione 7.3 che caratterizza le variabili aleatorie subgaussiane. In particolare, calcolare esattamente $\|X\|_{\psi_2}$

Dimostrazione.

$$\mathbb{E}[cX^2] = \frac{1}{\sqrt{2\pi}} \int \exp\left(cx^2 - \frac{1}{2}x^2\right) dx = \frac{1}{\sqrt{2\pi}} \int \exp\left(-\frac{1}{2}(1-2c)x^2\right) dx = \begin{cases} +\infty & \text{se } 1-2c \geq 0 \\ \frac{1}{\sqrt{1-2c}} & \text{altrimenti} \end{cases}$$

Per la proprietà (iii) usiamo il calcolo di sopra per $c = \lambda^2$ ottenendo che per c piccoli vale

$$\mathbb{E}[\exp(\lambda^2 X^2)] = \frac{1}{\sqrt{1-2c}} \leq 1 + 2c \leq e^{3c}$$

dunque la proprietà.

Per (iv) notiamo che per $t \geq \sqrt{2}$ vale

$$\mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] = \frac{1}{\sqrt{1 - \frac{2}{t^2}}} \leq 2 \Leftrightarrow t \geq \sqrt{\frac{8}{3}} \geq \sqrt{2}$$

Abbiamo dunque provato che $\|X\|_{\psi_2} = \sqrt{\frac{8}{3}}$

Esercizio 15.15. Calcolare la norma subgaussiana di $X \sim \text{Bernoulli}(p)$

Dimostrazione. Sia $p \neq 0$ allora vale

$$\mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] = pe^{\frac{1}{t^2}} + 1 - p \leq 2 \Leftrightarrow t^2 \geq \left(\ln \left(\frac{1+p}{p} \right) \right)^{-1}$$

da cui

$$\|X\|_{\psi_2} = \ln \left(\frac{1+p}{p} \right)^{-\frac{1}{2}}$$

□

Esercizio 15.16. Calcolare la norma subgaussiana di X v.a. di Rademacher.

Dimostrazione. Notando che $X^2 = 1$ quasi certamente otteniamo che

$$\mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] = \exp \left(\frac{1}{t^2} \right) \leq 2 \quad \Leftrightarrow \quad t \geq \frac{1}{\sqrt{\ln 2}}$$

□

Esercizio 15.17. Sia X v.a. limitata allora è subgaussiana

Dimostrazione.

$$\mathbb{E} \left[\exp \left(\frac{X^2}{t^2} \right) \right] \leq \exp \left(\frac{\|X\|_\infty^2}{t^2} \right) \leq 2 \quad \Leftrightarrow \quad t^2 \geq \frac{\|X\|_\infty^2}{\ln 2}$$

dove $\|\cdot\|_\infty$ è la norma del sup-essenziale.

Abbiamo dunque che

$$\|X\|_{\psi_2} \leq \frac{\|X\|_\infty}{\sqrt{\ln 2}} < \infty$$

Esercizio 15.18. Provare che le seguenti variabili aleatorie non sono subgaussiane:

1. Poisson
2. Esponenziale
3. Pareto
4. Cauchy

Dimostrazione.

1. Sia $X \in \mathbb{N}$ allora

$$\begin{aligned} \mathbb{P}(|X| \geq n) &= \mathbb{P}(X \geq n) > \mathbb{P}(X = n) = e^{-\gamma} \frac{\gamma^n}{n!} \geq e^{-\gamma} \frac{\gamma^n}{n^n} = \\ &= \exp(-\gamma + n \ln \gamma - n \ln n) \end{aligned} \quad (18)$$

Se, per assurdo, X fosse subgaussiana, dalla Proposizione 7.3 si avrebbe che esiste $C > 0$ tale che

$$\mathbb{P}(|X| \geq n) \leq \exp(\ln 2 - cn^2) \quad (19)$$

Mettendo insieme le disequazioni (18) e (19) si ottiene

$$\exp(-\gamma + n \ln \gamma - n \ln n) \leq \exp(\ln 2 - cn^2)$$

che è assurdo per n grande.

2. Se $t \geq 0$ allora

$$\mathbb{P}(|X| \geq t) = \mathbb{P}(X \geq t) = e^{-\gamma t} \quad (20)$$

Se, per assurdo, X fosse subgaussiana, dalla Proposizione 7.3 si avrebbe che esiste $C > 0$ tale che

$$\mathbb{P}(|X| \geq t) \leq 2e^{-ct^2} \quad (21)$$

Mettendo insieme le disequazioni (20) e (21) si ottiene

$$e^{-\gamma t} \leq 2e^{-ct^2}$$

che è assurdo per t grande

3. Ricordiamo che la v.a. di Pareto di parametri x_m e α ha valori in $[x_m, \infty)$ con densità $f(x) = \frac{\alpha x_m^\alpha}{x^{\alpha+1}}$ dunque se $t \geq x_m$ allora

$$P(|X| \geq T) = P(X > t) = \int_t^{+\infty} f(x) dx = x_m^\alpha t^{-\alpha}$$

e dunque non esiste un K tale che $x_m^\alpha t^{-\alpha} \leq 2e^{-\frac{t^2}{k_1^2}}$

4. Ricordiamo che la v.a. di Cauchy ha valori in \mathbb{R} con densità $f(x) = \frac{1}{\pi(x^2 + 1)}$ dunque

$$P(X \geq t) = \int_t^{+\infty} \frac{1}{\pi(x^2 + 1)} = \frac{1}{2} - \frac{\arctan(t)}{\pi}$$

ora non esistono costanti tali per cui $\frac{1}{2} - \frac{\arctan(t)}{\pi} \leq 2e^{-\frac{t^2}{k_1^2}}$

Esercizio 15.19. *Provare che $\|X\|_{\psi_2} \leq C(\sigma + |\mu|)$ se $X \sim \mathcal{N}(\mu, \sigma^2)$ dove C è una costante assoluta.*

Dimostrazione. Notiamo che se $X \sim \mathcal{N}(\mu, \sigma^2)$ allora $X \sim \sigma Z + \mu$ la tesi segue usando che $\|\cdot\|_{\psi_2}$ è una norma.

Esercizio 15.20. *Riformulare il Teorema di Hoeffding per v.a. di Rademacher indipendenti considerando ora una famiglia di v.a. di Bernoulli di parametro $\frac{1}{2}$ indipendenti.*

Dimostrazione. Questo risultato è stato dimostrato nel Corollario 7.13.

Esercizio 15.21. *Lancio una moneta onesta N volte. Provare che la probabilità di avere almeno $\frac{3}{4}N$ teste è limitata dall'alto da $e^{-\frac{N}{8}}$.*

Dimostrazione. Consideriamo le v.a.

$$X_i = \begin{cases} 1 & \text{se all}'i\text{-esimo lancio esce testa} \\ 0 & \text{altrimenti} \end{cases}$$

Allora X_1, \dots, X_N sono Bernoulli di parametro $\frac{1}{2}$ e applicando la disuguaglianza di Hoeffding otteniamo

$$\mathbb{P}\left(\sum_{i=1}^N X_i \geq \frac{3}{4}N\right) = \mathbb{P}\left(\sum_{i=1}^N \left(X_i - \frac{1}{2}\right) \geq \frac{3}{4}N - \frac{N}{2}\right) \leq e^{-\frac{N}{8}}$$

□

Esercizio 15.22. *Usando il risultato ottenuto nell'Osservazione 26, se l'algoritmo dà risposta corretta con probabilità del 70% determinare il minimo numero di iterazioni N affinché con probabilità almeno 90% la decisione presa (con majority vote) sia corretta. Consideriamo lo stesso problema se prendiamo 95% invece di 90%*

Esercizio 15.23. *Tale Esercizio è stato dimostrato come Lemma 8.3.*

Esercizio 15.24. *Sia X vettore gaussiano standard e $O \in O(n)$. Provare che OX è gaussiano standard.*

Dimostrazione. OX è gaussiano essendo immagine lineare di un vettore gaussiano. Per la Proposizione 11.3, inoltre, $OX \sim \mathcal{N}(0, \Gamma)$ con $\Gamma = OO^T = I_n$

Esercizio 15.25. Questo esercizio è stato dimostrato come Proposizione 11.6

Esercizio 15.26. Sia G matrice gaussiana standard $n \times n$. Allora, fissato $O \in O(n)$, le matrici OG e GO sono entrambi matrici gaussiane standard.

Dimostrazione. Proviamo che le entrate di OG sono v.a. i.i.d. gaussiane standard.

Se $G = (G_1 \ \dots \ G_n)$ consideriamo il vettore $X = \begin{pmatrix} G_1 \\ \vdots \\ G_n \end{pmatrix}$.

Per l'esercizio precedente il vettore

$$\tilde{O}X = \begin{pmatrix} O & & \\ & \ddots & \\ & & O \end{pmatrix} X$$

è gaussiano standard e dunque ha entrate i.i.d. gaussiane standard.

La tesi segue notando che OG e $\tilde{O}X$ hanno le stesse entrate.

□

Esercizio 15.27. Consideriamo $\chi = [0, 1]$ con $P_X \sim \mathcal{U}([0, 1])$. Proviamo che la classe di funzioni

$$\mathcal{F} = \{1_S \mid S \subseteq [0, 1] \text{ finito}\}$$

non è di Glivenko-Cantelli.

Data $f \in \mathcal{F}$ si ha

$$P_X(f) = \int_0^1 f(x) P_X(dx) = 0$$

infatti P_X da massa nulla ai singoli punti e f non è nulla solo su singoli punti.

Notiamo che se $f = 1_{\{X_1, \dots, X_n\}}$ allora $\mathbb{P}_n(f) = 1$ e quindi

$$\|\mathbb{P}_n - P_X\|_{\mathcal{F}} = \sup_{g \in \mathcal{F}} |\mathbb{P}_n(g) - P_X(g)| \geq 1 - 0 = 1$$

e dunque non può essere di Glivenko-Cantelli

Esercizio 15.28. Sia $X \sim \mathcal{N}(0, 1)$. Calcolare esplicitamente $\mathbb{E}[\exp(cX^2)]$ e verificare direttamente le proprietà (iii) e (iv).

Dimostrazione.

$$\mathbb{E}[\exp(cX^2)] = \frac{1}{\sqrt{2\pi}} \int e^{cx^2} e^{-\frac{1}{2}x^2} dx = \begin{cases} \frac{1}{\sqrt{1-2c}} & \text{se } 1 - 2c > 0 \\ +\infty & \text{altrimenti} \end{cases}$$

Per la verifica della proprietà (iii) si usa la formula di prima con $c = \lambda^2$ ottenendo

$$\mathbb{E}[\exp(\lambda^2 X^2)] = \frac{1}{\sqrt{1-2\lambda^2}} \leq 1 + 2c \leq e^{3c} \text{ per } c \text{ opportunamente piccolo}$$

Un semplice calcolo prova che $\|X\|_{\psi_2} = \sqrt{2}$

Esercizio 15.29. Sia $T \subseteq \mathbb{R}^n$ allora

$$w(T) = \frac{1}{2} \mathbb{E} \left[\sup_{x, y \in T} |\langle g, x - y \rangle| \right]$$

Dimostrazione.

$$\begin{aligned} W(T) &= \frac{1}{2}w(T - T) = \frac{1}{2}\mathbb{E} \left[\sup_{x,y \in T} \langle g, x - y \rangle \right] = \\ &= \frac{1}{2}\mathbb{E} \left[\sup_{x,y \in T} \max \{ \langle g, x - y \rangle, \langle g, y - x \rangle \} \right] = \frac{1}{2}\mathbb{E} \left[\sup_{x,y \in T} |\langle g, x - y \rangle| \right] \end{aligned}$$

Esercizio 15.30. Sia $T \subseteq \mathbb{R}^n$ con $T = -T$ allora

$$w(T) = \mathbb{E} \left[\sup_{t \in T} |\langle g, t \rangle| \right]$$

Dimostrazione.

$$w(T) = \mathbb{E} \left[\sup_{t \in T} \langle g, t \rangle \right] = \mathbb{E} \left[\sup_{t \in T} \max \{ \langle g, t \rangle, \langle g, -t \rangle \} \right] = \mathbb{E} \left[\sup_{t \in T} |\langle g, t \rangle| \right]$$

□

Esercizio 15.31. La classe di funzioni $\mathcal{F} = \{1_{[-\infty, t]} \mid t \in \mathbb{R}\}$ ha discriminante polinomiale di ordine 1

Dimostrazione. Fissata una successione x_1^n e data $f = 1_{(-\infty, t]}$ a meno di permutare gli indici in modo che la successione sia ordinata in maniera crescente si ha

$$(f(x_1), \dots, f(x_n)) = (1, \dots, 1, 0, \dots, 0)$$

e dunque se ψ è la permutazione richiesta otteniamo

$$\psi(\mathcal{F}(x_1^n)) = \{(0, \dots, 0), (1, 0, \dots, 0), \dots, (1, \dots, 1)\}$$

e dunque $|\mathcal{F}(x_1^n)| = n + 1$

□