

① 2018.1.1
 אספרות
 אמצעית

זאת התרגילים מאתחילנו .

הוא מתבקש עוד 8-7 שיעורים ולתור אמן שיעורי חללה .

לא יהיה מתחן בהסתהר. כל נושא בהתניה עדיין בתשלמה. כנראה
 יתבני יתבה אר השאלה על התואר שלו והמחצה יתבה אר השאלה

על התואר של ההכרזה. מתקלה השאלה לא יהיו קלג .

טא (שלה) סי אי מילום - dinazil@notes-heaven.com

זם הקשה - מחלה על תואר השיעורי החללה .



המחצה שלנו היום היא זהה מהט המחלה על הדברים .

מאתחיל מידה תישיבה ושלג התפלגה . יש אר אורה המצגים X

לנו ציממאלה X ופליבן תווה y מתיק מרחם תווה Y

אמרה של התפלגה D (משל) X x Y וממנה לקלחור הציממאלה .

אם הייתה (תנוה) לנו ההתפלגה אז לא אמש הייתה בעיה מחצה

נניח ש - $X = \{a_1, \dots, a_n\}$; $Y = \{-1, 1\}$

ונניח שיש לנו טבלה של הסתברויות :

$y \setminus x$	a_1	a_2	a_3	---	a_n
1					
-1					

$\sum p_{i1} = P(Y=1)$
 $\sum p_{i-1} = P(Y=-1)$

הסתברות מוגנה - $P(X|Y) = \frac{P(X,Y)}{P(Y)}$. זה (נרמ) לנו צוק לנרמל

אר ההתפלגה כן שטבוט שורה יהיה 1 :

$$\sum_x P(X|Y) = \sum_x \frac{P(X,Y)}{P(Y)} = \frac{\sum_x P(X,Y)}{P(Y)} = \frac{P(Y)}{P(Y)} = 1$$

בצורה צומה אפשר לנרמל כן שטבוט בטל עמידה יהיה 1 - $P(Y|X)$

עכשו $P(X|Y=1)$ לו פונקציה הסתברות כי הסטבוט שלה היא 1 .

זה אחר מה הסיכוי של ציממה X בהנרמל שידוע לנו שציממה היא

תישיבה .

בע"ה ההחמה שלנו היא המחלה למהמט מה יתר גודל -

$P(X=1|X)$ או $P(Y=-1|X)$ ואמיש לנו טבלה לו לא בעיה!

$$p(y|x) = \frac{p(x|y)p(y)}{p(x)} \quad \text{נוסחה בייס -}$$

לפי הנוסחה הנ"ל רכיב זה שווה אף $p(y=1|x)$! $p(y=-1|x)$ אם $p(x)$ זה שווה אף

$p(x|y=1)p(y=1)$! $p(x|y=-1)p(y=-1)$
 בעצם בהעיון למידה יוצאים אף $p(y=1)$! $p(y=-1)$ ואם לא יוצאים אז בעצם מנותנים שהם שווים - סומך הנתפס אף $p(x|y=1)$! $p(x|y=-1)$ אז מה שצריך להשוות זה לא הגופל שנקרא (כאן) -

$p(x|y=1)$! $p(x|y=-1)$
 פשוט אחרת, ש זה כמובן לא נתן אם נתונה לנו הנתפס אף -
 אז ש מה שעושים בתחום הלמידה החישובית הוא לראות אלו נתונים
 מתקנה לא נתונה לנו הנתפס אף.


PAC הוא המושג הניתן בתחום הלמידה החישובית שבו זא עושים שם
 הנתה של הנתפס אף אף אשתיים אדם. (בשאר הנתונים שלמנו, אם
 אחרת אז זה אומר למעשה יש הנתה של הנתפס אף (נוח)
 מופל PAC אחר אף הנתה היא : יש מתקנה היפוכה ל
 ונגזרים ציב, ע וביטחון ע וכל סמך היציאות שלנו ענו
 אנתה רוצים למצוא היפוכה h ששגיאה שלה לקיימת

$$P(\text{err}(h) \leq \epsilon) \geq 1 - \delta$$

אשר היציאות בשלבם להשיג אף זה (δ, ϵ, m) והוא גלוי
 אקורט ה- ϵ וה- δ אף הנתפס אף.

לא תמיד אפשר להשתמש ה-PAC, אם המתקנה C סופי
 אז צריך $m \geq \frac{1}{\epsilon} \log \frac{|C|}{\delta}$ ואז אם C אינסופי אף ה- $\dim VC$
 שלה סופי אז אם אפשר למצוא ! $m \geq \frac{1}{\epsilon} \log \frac{1}{\delta} + \frac{d}{\epsilon} \log \frac{1}{\delta}$
 אם מוצא VC של C אינסופי אז אי אפשר למצוא PAC -
 אי אפשר למצוא אף שיתוק של הנתפס אף יש רק משפחה מצומצמת
 של העיון שבה זא צריך לשערך הנתפס אף. אבל בשלבם קורה, זה קטום!
 למשל, המתקנה ההיפוכה של אפיונים ע'איים $f(x) = \text{sgn}(w^T x - b)$
 יש מוצא VC סופי אף אפשר למצוא אף.

2



אפשר לראות מהתוספת של m שלבים הנימצא
 \forall קטן יותר אז אפשר לקחת פתרון צמוד-אלו
 רצו עמאוד עפי ע; δ נתונים.

אז במקרה של אפידים (סתם על אפידים) סימולט
 זה שלבים בלבד $\delta - C_f$. אפשר לראות

ע- $VCD(C_f) = \min\{\frac{1}{\gamma^2}, n\} + 1$ אצל $VCD(C) = n + 1$

אז, אם δ אפידים (קטני או הנימצא \forall וזה אפשר לנו לקחת
 פתור צמוד. אז ב הנימצא של אפידים SVM הובו עמאוד
 אפידים שלמים כמה שיותר אפידים.


אפשר לסדר את העניינים הם ע- $\delta = \frac{1}{\|w\|}$ אפידים לנו בעניי

אופטימיזציה: $\min \frac{1}{2} \|w\|^2 + \lambda \sum \epsilon_i$ s.t $y_i(w^t x_i - b) \geq 1 - \epsilon_i$

הבעיה הדואלית היא $\max \sum \alpha_i - \frac{1}{2} \sum \alpha_i \alpha_j y_i y_j x_i^t x_j$
 s.t $0 \leq \alpha_i \leq \lambda$
 $\sum \alpha_i y_i = 0$

עמה זמנו לבעיה הדואלית? כי שלם אפשר אפידים ה- kernel trick
 זכרנו אפילו אם בחירת הנחוק (הקצוות עא נתנו) לפרסדה ע' יורה
 עא עינאויג אז אפשר לעבור עמרתם לכוה הו אולי אפשר לעבור
 הפרדה עינאויג.

אם מניחים שהקצוות שנתנו הם אהתפזז נורמלי אז יש צדק בעלת
 אהתרה עינאויג עמרתם על אישור אפידים.



עני שיש לנו שגי קבוצות - צודאמאל
 תלבינה עם מרכז μ_1 ו צודאמאל
 שלוליה עם מרכז μ_2 .

אנתנו רוצים למצוא אישור ש שלול
 (סו) אה הצודאמאל רק שנוס (זהפריד

אולי - אז אנתנו רוצים שהמרכלים והיו חתקים כמה שיותר לה מלה אחר
 ההסדה. עמש ציר ה-x בציר מקיים אה לה אסל ציר ה-x עא אפריד טאב
 כיש לנו שם (קצוות חופיות. אם נסתכל צונקא על ציר ה-y כחפריד
 אז אנתם הוחתק בין המרכלים) או הכי גדולים אה אין תפסה של הקצוות

$\max \frac{\hat{\mu}_1 - \hat{\mu}_2}{\hat{\sigma}_1^2 + \hat{\sigma}_2^2}$ כס מה שאנחנו רוצים לפתור זה אולי הבעיה האופטימלית
 כולם $\hat{\sigma}_i^2$ זה אולי משהו אחר. ואולי אפשר להחליף את זה בהנחה
 $Aw = Bv$ ראשון זה של $B^{-1}A$.

גם ה-PCA יש הנהגה של התפלגות נורמלית. הרעיון היה שיש מטריות שבה
 יש יתרון ואנחנו רוצים "לרונף" את זה. את $\begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ רוצים להחליף
 למתחלק יותר $\begin{pmatrix} x_1' \\ \vdots \\ x_n' \end{pmatrix}$ ככה שאין תלות סטטיסטית בין הכניסות.
 מטריצה ה covariance של X היא מטריצה סימטרית. למתחלק ההתחלה
 מטריצה ה covariance של X' היא מטריצה. ככה, מטריצה
 Covariance אלוטונית זה שקום לאי-תלות סטטיסטית רק אם
 ההתפלגות היא נורמלית.

אם אנחנו מניחים ש- $X \sim N(\mu, E)$ אז

$$p(x) = \frac{1}{\sqrt{2\pi} |E|} e^{-\frac{1}{2}(x-\mu)^T E^{-1} (x-\mu)}$$
 $\theta = (\mu, E)$

אם נתונים דיוטמוסטר ודיטמוסטר שלילי אז מטריצה לא-התפלגות
 ה(נוטמוסטר) החיובית ואם ההתפלגות ה(נוטמוסטר) שלילית:
 אם $y=1$ אז $S = \{x_1, \dots, x_m\}$; $i.i.d$

$$\max_{\theta} p(S|\theta) = \max_{\theta} \prod_i p(x_i|\theta)$$

$$\Leftrightarrow \max \log p(S|\theta) = \max \sum \log p(x_i|\theta)$$

אז $\arg \max_{\theta} p(S|\theta) = \arg \max_{\theta} \sum \log p(x_i|\theta)$ וזה הרי שפותר את הבעיה
 הבעיה היא שאין כוח σ לחיבור מדיאטור של מדידות התנאים הדיטמוסטר.

נניח שרוצים למצוא משטח מפריד בין שני התפלגות נורמליות שישנן התנאים

$$p(x|h_1) = N(\mu_1, E)$$

$$p(x|h_2) = N(\mu_2, E)$$

$$p(h_1|x) - p(h_2|x) = 0$$

$$p(h_1) = p(h_2)$$
 אז המשטח המפריד הוא $p(x|h_1) - p(x|h_2) = 0$

אישה יותר מתקדמת מניה של התפלגות היא קואורדינטיב לניאכור של התפלגות
 יפוצת. זה נשמע קצת יותר מדיאלוגי מההנחה של התפלגות נורמלית.

3

נניח $Y = \{y_1, \dots, y_k\}$ - $x \in \mathbb{R}^n$ -

$$P(X) = \sum_y p(x|y)p(y) = \sum_{j=1}^k \underbrace{p(x_1, \dots, x_n | y=y_j)}_{\substack{\text{נניח שזו התפלגות} \\ \text{יחידה}}} p(y=y_j)$$

זרשיו רב-ממדים $P(X)$ אך צבים, זרשם $p(x)$ כן $p(x_1, \dots, x_n | y=y_j)$ $p(y=y_j)$.

$$p(x_1, \dots, x_n | y) = p(x_1 | y) \dots p(x_n | y)$$

צמצום: יש שני מסבוגים. צמצום סיכוי p ו- q ובעני סיכוי q ו- p . אנחנו בוחנים מסבוג סיכוי g וקדם אך הראשון, ואם מסבים אלו 3 מסבים.

נניח שנתנו לנו תוצאה של ניסויים רבים והתורה היא זמנים λ, q, p . יש כן משנה תמיד והיא המסבוג שנבחר באותו ניסוי $y_i \in \{1, 2\}$ (סמן i -יא תוצאה 1 ו- 2 - סומן 3 - תוצאה 3 ו- 2 - תוצאה 2).

$$p(x_i) = p(x_i | y_i=1) p(y_i=1) + p(x_i | y_i=2) p(y_i=2)$$

סמן m_i - אך מספר התצפיות שיש x_i - אך

$$p(x_i) = \lambda p^{m_i} (1-p)^{3-m_i} + (1-\lambda) q^{m_i} (1-q)^{3-m_i}$$

$\theta = (p, q, \lambda)$ אך, מצויים אך זה תציי - אופטימיזציה θ

$S = (x_1, \dots, x_m)$ - אך מה שאנחנו רוצים יהיה

$$\begin{aligned} \max_{\theta} \log p(S|\theta) &= \max_{\theta} \log \prod_i p(x_i|\theta) = \\ &= \max_{\theta} \sum \log (\lambda p^{m_i} (1-p)^{3-m_i} + (1-\lambda) q^{m_i} (1-q)^{3-m_i}) \end{aligned}$$

לא תציי קשה. אם אופטימיזציה θ אופטימלית, אך קיים אלטרנטיב שמוצא θ שנוף אופטימום θ אופטימלית, אך אופטימלית. אנחנו צונו אך אלו.

אם x, y התפלגות מצויים אך באמצעות היחס - נינין θ

$$D(x||y) = \sum x_i \log \frac{x_i}{y_i}$$


נסמן \hat{P} אך ההתפלגות המפורית של הצמצום. הצמצום \hat{P}

$$\hat{P}_{i_1, i_2, i_3} = \frac{1}{m} |\{x_i = (i_1, i_2, i_3)\}|$$

אנחנו מחפשים אך ההתפלגות הכתומה P הכי קרובה להתפלגות - האופטימלית. סומן צבים אפיו אך ההצעה $\min_p D(\hat{P} || p)$

פוליטרה: יש לנו קבוצה של קטן ציפורים האצה נחל.

אמר שאנחנו רוצים לה זכור אונטופולציה לרתפלוג -
למצוא את ההסתברות לקטן ציפורים הם נקודה ביחס.



פוליטרה קצרה יותר פשוטה היא ההצעה של קביה. נניח
שאנחנו לנו שמתחיל ההחלטה היא 5 ושאנחנו מה-1
הרתפלוג. אז אנחנו ציבורים למצוא את $P = \binom{p_1}{p_6}$

$$p_i \geq 0 \quad \sum p_i = 1 \quad \sum_{i=1}^6 i p_i = 5$$

יש 6 משתנים ורק 2 משוואות. זה לא מספיק כדי למצוא פתרון יחיד.

לקחת אלמנט אחר למצוא את הפתרון זה האנטרופיה המקסימלית.

כאשר האנטרופיה היא $H(p) = -\sum p_i \log p_i$. מקסום האנטרופיה זו

למצוא התקרבות לרתפלוג אחידה.

אם רוצים להתקרב לרתפלוג אחר P_0 אז אה שאנחנו צריכים לה

למצוא את המינימום של האנטרופיה היחסית $D(P_0 || P)$ ביפוף

למצוא.

לפעמים אפשר לעשות פקטוריזציה של פונקציה - הרתפלוג למצוא

של הרתפלוג על גר קבוצה של משתנים. (זה מקרא אתנו) אה

שנקרא מינזים זרפיים.

2

הסקרה ב"סכנויות

ניג שיש לנו $X = \{x_1, \dots, x_n\}$ פונקציה הסתברות

כא $p(x_i) \geq 0$ לכל $1 \leq i \leq n$

$\sum_{i=1}^n p(x_i) = 1$

$p(x) = \begin{pmatrix} p(x_1) \\ \vdots \\ p(x_n) \end{pmatrix}$

אפשר להסתכל על $p(x)$ כווקטור
לכל וקטור הסתברות.

$p(x|y) = \frac{p(x,y)}{p(y)}$

הצורה צומה אפשר להגדיר וקטור הסתברות אומני

$p(Y=y_j) = \sum_x p(x, Y=y_j)$

$p(X=x_i | Y=y_j) = \frac{p(X=x_i, Y=y_j)}{p(Y=y_j)}$

סוג

התלות - $p(y)$ זהו שכיחות של $(x, Y=y_j)$ והוא וקטור

$\sum_x p(x|y) = \sum_{x_i} \frac{p(x_i, y)}{p(y)} = \frac{p(y)}{p(y)} = 1$

ואם יוצא זה אומר שהסתברות

$p(x|y) p(y) = p(x,y) = p(y|x) p(x)$

נוסחה בייס :

$\frac{p(y|x)}{\text{posterior}} = \frac{p(x|y) p(y)}{\frac{p(x)}{\text{evidence}}}$

או

כא מ"ד ברור למחלה טובה. לראות לא אמרנו שיש צורך אחרת
זה מ"ד נותן טעם מוסתה צ"ה.

פואמה: יש ערך שמקבלת פואמה עם ונותנת תוצאה חיובית או שלילית.

הפס היא או כרא או חולה סרטן $X = \{C, H\}$

הפזימה נוגדת ג' שלב $Y = \{+, -\}$

$p(+ | C) = 0.98$ נתונים הנתונים הסבוי:

$p(- | H) = 0.97$

$p(C) = 0.01$

החסרת האלה (ראים אנשים, אבל את שמרן אמנו היא לא מדויקת $p(C|+)$

וראן מ"יפה נוסחה בייס:

$p(C|+) = \frac{p(+|C) \cdot p(C)}{p(+)}$

$= \frac{p(+|C) p(C)}{p(+|C) p(C) + p(+|H) p(H)} = \frac{0.98 \times 0.01}{0.98 \times 0.01 + 0.02 \times 0.99} = 0.266$

נוסחה ההסתברות השלמה

אז עם העינה הלאה הבר עקול זהסומק על הנהל ...
 מה שיגום לנה לה לאעשם לשסכוני אחרתמה אחרתהססן - ההתפלגה
 הלאפריורי - היא מאפ רחוקה אסרויג אחידה, ואז לה אשפז על
 ההתפלגה הפוסטריורי.

הרבה פעמים לא (תונה לנו ההתפלגה האפריורי ואז אנומים לשפז אחידה.
 אז ואן ראונו שלנתה הנויש השפזוג אחזקות לנה...

עזרים טבאי למפוז אר $p(x|y)$ ואר $p(y)$ ואז לתש אר $p(y|x)$

פונמיה X וקסור גסמונים
 Y פואלונזה

אז $p(x|y)$ זה מה הסיכוי לגסמונים בלשם הנויגן המתלה.
 זה משפז מאוז טבאי למפוז אר יוסיר קל. רק גים קל למפוז אר
 הסיכוי של המתלה $p(y)$.

קצר יתר מסובק למפוז אר - $p(x|y)$ וסיכוי המתלה הנויגן
 הגסמונים. אכל זה פוקא או משפז שרודים לפזר ני אם Y ינו
 לקדם שני עזרים למשל אר אם באבן אדם עם גסמין x הינו
 כודים לפזר מה יתר קפול - $p(x|y=y_1)$ או $p(x|y=y_2)$.
 משלנו למפוז אר לה לה כמו אפוק

$$p(x|y=y_2)p(y=y_2) \quad ? \quad p(x|y=y_1)p(y=y_1)$$

אם אנונו אנוים שלהתפלגה האפריורי (הוא אחידה אפוק רק
 פהשוור אר ה likelihood (ראוי).

$$y^* = \operatorname{argmax}_y p(y|x) \quad \text{MAP}$$

זה הלקסומ הפוסטריורי - הוקודה שנויגה אר הלקסומ ההתפלגה
 הפוסטריורי


(תשבי)

$$y^* = \operatorname{argmax}_y p(y|x) = \operatorname{argmax}_y \frac{p(x|y)p(y)}{p(x)} = \operatorname{argmax}_y p(x|y)p(y) =$$

$$= \operatorname{argmax}_y p(x,y)$$

5

אם אנו יושבים על ההתפלגות המשותפת בשטח קבועים
 אר, x, מתנאים התאמה של מוצאים את הזרם המאפשר.



הקציה היא של א
 גמיר (גונה) אנו ההתפלגות
 והמשותפת.

$$y^* = \arg \max_y p(x|y) \quad \underline{ML}$$

באמצע ההסתברות מוכנס $X = \{0, 1\}$ ומכאן ההסתברות $Y = q$
 $p(x=0 | y=q) = q$
 $p(x=1 | y=q) = 1-q$
 q זה פשוט הסכום לקבל 0.

הנשיו נניח שיש לנו k הטלור ב"ת (iid) x_1, \dots, x_k
 נרצה לגרום את ההסתברות q שמתורה הסכום לקבל את ההסתברות
 (x_1, \dots, x_k) היא מקסימלית. למצוא נוצים למצוא את

$$\max_q p(x_1, \dots, x_k | q) = \max_q \prod_{i=1}^k p(x_i | q)$$

פכיש
 שוויון בין
 הצדדים
 שגורמים
 למקסימום
 מסתמים ב.

||
 $\max_q \log p(x_1, \dots, x_k | q) = \max_q \sum_{i=1}^k \log p(x_i | q)$
 (נוצו log משני הצדדים ונקבל)

יהי λ מספר הפזמים לקבלנו $x_i = 0$

$$\lambda = \{ x_i = 0 : i = 1, \dots, k \}$$

$$\Rightarrow q^* = \arg \max \{ \lambda \log q + (k-\lambda) \log(1-q) \}$$

(משום ש- $p(x|q) = \begin{cases} q & x=0 \\ 1-q & x=1 \end{cases}$ ומאז עושים סכום)

פותר את המשוואה האופטימלית. נגזור את הפונקציה לפי q:

$$\frac{\lambda}{q} - \frac{k-\lambda}{1-q} = 0$$

$$\Rightarrow \lambda(1-q) - q(k-\lambda) = 0$$

$$\Rightarrow \lambda - qk = 0 \Rightarrow q = \frac{1}{k} \lambda$$

קיבלנו משוואה דינמית: וההסתברות היא המספר היחסי של ההסתברות
 שצאו 0.

הסתברות $\mathcal{N}(\mu, E)$ (נורמלית)

μ - התווך

E - מטריצה שנוגדת משתנה אינדיבידואליזם הם השונות ומחולק

אבל זהו השונות והמשותף


ההסתברות לתתם וקטור x בהינתן למטריצה E והתווך μ

(נורמלית) $\theta = (\mu, E)$ (היא)

היא להסתברות
של המשתנה

$$p(x | \theta) = \frac{1}{(2\pi)^{n/2} |E|^{1/2}} e^{-\frac{1}{2}(x-\mu)^T E^{-1}(x-\mu)}$$

הפרמטרים μ ו- E הם אופטימליים אם אחרת ושלנו הם כיוון



נתונה סדרה $x_1, \dots, x_n \in \mathbb{R}^n$ iid והסתברות היא אצלם

$$\theta^* = \arg \max_{\theta} p(x_1, \dots, x_n | \theta) \quad \theta^* = (\mu^*, E^*)$$

אם היה לנו את $p(\theta)$ של היינו מתלבים את

$$\max_{\theta} p(x_1, \dots, x_n | \theta) p(\theta) \equiv \max_{\theta} p(\theta | x_1, \dots, x_n)$$

זה הבעיה הפשוטה. אבל אם אין לנו את ה-prior איתנו

התפלגות אחידה ואת אחרים - ML + MAP

אם מה שמתני רוצים למצוא זה

$$\begin{aligned} \theta^* = \arg \max_{\theta} p(x_1, \dots, x_n | \theta) &= \arg \max_{\theta} \prod_{i=1}^n p(x_i | \theta) = \\ &= \arg \max_{\theta} \underbrace{\sum_{i=1}^n \log p(x_i | \theta)}_{L(\theta)} \end{aligned}$$

$$L(\theta) = \frac{1}{2} n \log(2\pi) - \frac{1}{2} n \log |E| - \frac{1}{2} \sum_{i=1}^n (x_i - \mu)^T E^{-1} (x_i - \mu)$$

$$\frac{\partial L}{\partial \mu} = 0, \quad \frac{\partial L}{\partial E} = 0 \quad \text{עדיין (כזה) אצור (ו) השווה}$$

$$E = \sigma^2 I \quad \text{על-כך (אם) הבעיה הפשוטה}$$

$$|E| = \sigma^{2n} \quad ; \quad E^{-1} = \frac{1}{\sigma^2} I \quad \text{אם}$$

6

פרמטר σ - דבר ופרמטר μ - דבר ופרמטר $\frac{1}{2}kn \log(2\pi)$

$$L(\theta) \equiv -kn \log \sigma - \frac{1}{2} \sum_{i=1}^k \frac{\|x_i - \mu\|^2}{\sigma^2}$$

$$\Rightarrow \frac{\partial L}{\partial \sigma} = -\frac{kn}{\sigma} + \sigma^{-3} \sum_{i=1}^k \|x_i - \mu\|^2 = 0$$

$$\Rightarrow -kn + \frac{1}{\sigma^2} \sum_{i=1}^k \|x_i - \mu\|^2 = 0$$

$$\Rightarrow \sigma^2 = \frac{1}{kn} \sum_{i=1}^k \|x_i - \mu\|^2 \quad (= \sigma^{*2})$$

על מנת יצא לנו רצון (חוקה) - נניח

ולכן $E = \begin{pmatrix} \sigma_1^2 & & 0 \\ & \ddots & \\ 0 & & \sigma_n^2 \end{pmatrix} \quad \sigma_1 = \sigma_2 = \dots = \sigma_n = \sigma$

$$\frac{1}{k} \sum \|x_i - \mu\|^2 = \sum \sigma_i^2 = n \sigma^2$$

$$\Rightarrow \frac{1}{n} \cdot \frac{1}{k} \sum \|x_i - \mu\|^2 = \sigma^2$$

$$\frac{\partial L}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^k (x_i - \mu) = 0$$

$$\Rightarrow \sum_{i=1}^k (x_i - \mu) = 0$$

$$\Rightarrow \sum_{i=1}^k x_i - k\mu = 0$$

$$\Rightarrow \mu = \frac{1}{k} \sum x_i \quad (= \mu^*)$$

אם קיבלנו נאן או המצבים שאנחנו מחכים - תחלה ושלנו
 פני שרבענו אותן מראש!

$$E = \frac{1}{k} \sum (x_i - \mu)(x_i - \mu)^T \quad \text{פרמטר והם מתקדם}$$

צואתה: נניח $\mathcal{Y} = \{h_1, h_2\}$ (תפס) א

$$h^* = \underset{h_1, h_2}{\operatorname{argmax}} p(h|x)$$

המשטח המפריד (פונקציה) x היא


$$p(h_1|x) - p(h_2|x) = 0$$

$$p(x|h_1) - p(x|h_2) = 0 \quad \text{אם נניח } p(h_1) = p(h_2) \text{ אז המשטח היא}$$

$$p(x|h_1) \sim \mathcal{N}(\mu_1, E) \quad \text{נויג ע-}$$

$$p(x|h_2) \sim \mathcal{N}(\mu_2, E)$$

בזמנו אנו שואלים את השאלה האם המרחקים הם זהים



$$p(x|h_1) - p(x|h_2) = 0 \Rightarrow p(x|h_1) = p(x|h_2)$$

$$\Rightarrow \frac{p(x|h_1)}{p(x|h_2)} = 1 \Rightarrow \log p(x|h_1) - \log p(x|h_2) = 0$$

$$\Rightarrow -\frac{1}{2}(x-\mu_1)^t E^{-1}(x-\mu_1) + \frac{1}{2}(x-\mu_2)^t E^{-1}(x-\mu_2) = 0$$

$$\Rightarrow x^t E^{-1}(\mu_1 - \mu_2) - \frac{1}{2}\mu_1^t E^{-1}\mu_1 + \frac{1}{2}\mu_2^t E^{-1}\mu_2 = 0$$

$$- \frac{1}{2}(\mu_1 + \mu_2)^t E^{-1}(\mu_1 - \mu_2)$$

$$\Rightarrow \underbrace{x^t E^{-1}(\mu_1 - \mu_2)}_w - \underbrace{\frac{1}{2}(\mu_1 + \mu_2)}_{\mu} \underbrace{E^{-1}(\mu_1 - \mu_2)}_w = 0$$


$$\Rightarrow w^t (x - \mu) = 0$$

קובענו למעשה המרחק הוא זהה אישור! בזמן המרחק הוא ישר
 המרחק הפונקציה שלו הם בדיוק הפרמטרים של LDA שזהו הכל
 בזמן אתר החיפוש.

מה גם SVM הוא אופטימיזציה מבחינה כזו היא לא אנה שום
 דבר זה הכתוב לא אשער אותה. אתם אנו מנסים זה
 כפי שצריך אלא ציבור.

אתר אין שיפור. שבוץ הוא אין שיפורים.
 השבוץ לאחר מכן מנסים אם בעני אדם בליש.

12.02.08
 מא' זמנא



Gibbs Max Entropy, יחסיות, אנטרופיה

נראה שהתפלגות אנטרופיה של אמצעים בטרם היא היקרה ביותר, האמתן ML, זה התפלגות האמיתית.

(ההשענה הכזו לחלוטין נאגרת לוויה כמה שרשונים קוצים)

נניח ש- $\{a_1, \dots, a_m\} - X$; $p(a|\theta)$ ההסתברות לצדדים
 $a \in X$ יהי אמצעם iid $x_1, \dots, x_m \in X$

- ציבור מופץ \sqrt{a} היא אמצע הפרזאים ש- a הופים מוצאים

$$f(a) = |\{i : x_i = a\}|$$

- ההתפלגות האמיתית של a היא

$$\hat{p}(a) = \frac{1}{\sum_{b \in X} f(b)} f(a) = \frac{1}{m} f(a)$$

מה הקשר בין $f(a)$ ל- $p(a)$?

$$p(x_1, \dots, x_m | \theta) = \prod_{a \in X} p(a|\theta)^{f(a)}$$

$$\Rightarrow \max_{p \in Q} p(x_1, \dots, x_m | \theta) = \max_{p \in Q} \prod_{a \in X} p(a|\theta)^{f(a)}$$

נאמר $Q = \{q \in \mathbb{R}^n : q_i \geq 0, \sum q_i = 1\}$ אומה וקטורי הסתברות.
 - $p_i = p(a_i|\theta)$; $f_i = f(a_i)$ / מסן

אלו אומנו ציבורים רשומה בעזרת אנטרופיה

$$\max_{p_1, \dots, p_n} \prod_{i=1}^n p_i^{f_i} \quad \text{s.t. } p_i \geq 0, \sum p_i = 1$$

$$\max_{\substack{p_1, \dots, p_n \\ \text{s.t. } p_i \geq 0 \\ \sum p_i = 1}} \prod p_i^{f_i} \equiv \max_{\substack{p_1, \dots, p_n \\ \text{s.t. } p_i \geq 0 \\ \sum p_i = 1}} \sum f_i \log p_i$$

נאמר שהתפלגות זכרון אדם (השאלה מה אלו קיזו) ונשכח (קודם מה שזכרון)

$$\mathcal{L}(p_i, \lambda, \mu) = \sum f_i \log p_i - \lambda (\sum p_i - 1) - \mu$$

$$\frac{\partial \mathcal{L}}{\partial p_i} = \frac{f_i}{p_i} - \lambda = 0 \Rightarrow p_i = \frac{1}{\lambda} f_i$$

$$\Rightarrow 1 = \sum p_i = \frac{1}{\lambda} \sum f_i \Rightarrow p_i = \frac{1}{\sum f_j} f_i = \hat{p}_i$$

סכום $f_i \geq 0$ קיבלו בתנאים $p_i \geq 0$.
 זיקתן ה-ML אומר שהסתברות האפשרית היא \hat{p} (אמן) (הכאן) (האמת)

אנצ'רופיה יחסית - x, y וקטרים. האנצ'רופיה היחסית

בינום היא $D(x||y) = \sum_i x_i \ln \frac{x_i}{y_i} - \sum x_i + \sum y_i$

סך x, y וקטורי התפלגות סך $\sum y_i = \sum x_i = 1$ וכן $D(x||y) = \sum x_i \ln \frac{x_i}{y_i}$ - KL-Divergence

D יש לא משיק? קצת ב, D לא סימטרית. אם x שוויון המשוואה לא מתקיים. הצבנו היתר שמתקיים היא תוספת.

$D(x||y) \geq 0$: טענה

הוכחה: (ישנה השיטה של ליוויוס)

log-sum inequality: $\sum x_i \ln \frac{x_i}{y_i} \geq (\sum x_i) \ln \frac{\sum x_i}{\sum y_i} = \bar{x} \cdot \ln \frac{\bar{x}}{\bar{y}}$

$\ln(x+1) > \frac{x}{1+x}$ $x > -1, x \neq 0$

נא לא להיגרר

$D(x||y) \geq \bar{x} \ln \frac{\bar{x}}{\bar{y}} - \bar{x} + \bar{y}$

$\bar{x} \ln \frac{\bar{x}}{\bar{y}} \geq \bar{x} - \bar{y}$? נא

$a \ln \frac{a}{b} \geq a - b \iff \ln \frac{a}{b} \geq 1 - \frac{b}{a} \iff \ln x \geq 1 - \frac{1}{x}$

$\ln(x+1) > \frac{x}{x+1}$, $y = +1$ $\ln y > \frac{y-1}{y} = -\frac{1}{y}$
 $x > -1$ $y > 0$

☺ \bar{y}, \bar{x} אולי זה מתקיים.

$\min_p D(p||\hat{p})$ s.t $p \geq 0, \sum p_i = 1$

$\sum f_i \ln f_i - \sum f_i \ln p_i - \sum f_i + 1$

$\equiv \max \sum f_i \ln p_i$ s.t $p_i \geq 0, \sum p_i = 1 \implies p_i^* = \frac{1}{\sum f_i} f_i = \hat{p}_i$

8


מבצע את p או שלילי. מצד שני p יושב על $\sum p_i = 1$ - אישור \rightarrow

$\sum p_i = 1$ יש משואה סימטרית

(שמה זה e^{-p_i} - Scaling) זהו פשוט אזהרה

על f_i בלבד, אבל לא על f_i - אי-שלילי

לפני f_i - אי-שלילי.



איפה זה - $D(p \| \frac{1}{n} \vec{1})$ מינימום $D(p \| \frac{1}{n} \vec{1})$ (האינטרוינטיב)

מצד שני, איפה זה אם p מצד שני? D - לא סימטרית. זה לא יוצא אלא צבירה.

(לכונן שלבאנסרופיה) $H(x) = -\sum x_i \ln x_i$ הוא

$$D(p \| \frac{1}{n} \vec{1}) = \sum p_i \ln p_i - \sum p_i \ln \frac{1}{n} =$$

$$= \sum p_i \ln p_i - \sum p_i \ln 1 + \sum p_i \ln n =$$

$$= \sum p_i \ln p_i + \ln n (\sum p_i) = \ln n - H(p)$$

$$\Rightarrow \operatorname{argmin}_p D(p \| \frac{1}{n} \vec{1}) = \operatorname{argmax}_p H(p)$$

תקנו לפי זה או שיש אישור שום מצד α בליק לפי זה.
 יתירה, וזה או שיש אישור α או שיש אישור α .
 נניח שיש לנו קבוצה וישוואים מה הסיכוי שהיא תצא i
 \checkmark אישור α

$$\max_p H(p) \text{ s.t. } p \geq 0, \sum p_i = 1, \sum \alpha_i p_i = \beta$$

$$\mathcal{L}(p, \lambda, \mu) = -\sum p_i \ln p_i + \lambda (\sum p_i - 1) + \mu (\sum \alpha_i p_i - \beta)$$

$$\frac{\partial \mathcal{L}}{\partial p_i} = -(\ln p_i + 1) + \lambda + \mu \alpha_i = 0$$

$$\Rightarrow \ln p_i = (1 + \lambda) + \mu \alpha_i$$


$$\Rightarrow p_i = e^{1+\lambda} \cdot e^{\mu \alpha_i}$$

$$\Rightarrow 1 = \sum p_i = e^{1+\lambda} \sum e^{\mu \alpha_j}$$

$$\Rightarrow \boxed{p_i = \frac{1}{Z} e^{\mu \alpha_i}} \text{ Boltzmann-Gibbs Distribution}$$

$$Z = e^{1+\lambda} = \sum e^{\mu \alpha_j}$$

איך זה נראה ?



המסוף של י -


$$\min_p D(p \parallel p_0) \text{ s.t. } p_i \geq 0, \sum p_i = 1, \sum \alpha_i p_i = \beta$$

$$\Rightarrow p_i^* = \frac{1}{Z} p_{0i} e^{\alpha_i \beta}$$

$$\min_p D(p \parallel p_0) \text{ s.t. } p_i \geq 0, \sum p_i = 1, \sum_j f_{ij} p_i = b_j \quad j=1, \dots, k$$

$$\Rightarrow p_i^* = \frac{1}{Z} p_{0i} e^{\sum_{j=1}^k \alpha_j f_{ij}}$$

זהו המקרה הכללי של התפלגות בולצמן-גבס.

נניח שיש לנו מרחב  ובו נמצאים כמה נקודות בתוספת

ההסתברות של הן. אומתנו נוצרים עשרה אינטרפולציה. אם שתיים מהם זה שיקולים מקומיים ראש הנקודה לעבר. אלו מהם אם הנקודה צלולה מאד? ויש לנו אינטרפולציה שמתקיימים $(\sum f_{ij} p_i = b_j)$ ואנחנו נחשף את האינטרפולציה לפי קרובה להתפלגות אחידה. זה בדיוק מה שרשינו למטה!

$$\mathcal{P} = \{ p \in \mathbb{R}^n : p \geq 0, \sum p_i = 1, \mathbb{E}[f_j] = \mathbb{E}[f_j] \} \quad \mathbb{E}[f_j] = \sum f_{ij} p_i, \quad \mathbb{E}[f_j] = b_j$$

$$\mathcal{Q} = \{ q \in \mathbb{R}^n : q \text{ Gibbs-Distribution} \}$$

$$\min_{q \in \mathcal{Q}} D(\hat{p} \parallel q) - ML$$

אחד האלגוריתמים הנפוצים לפתרון הקסיה הזו הוא *Iterated Scaling*.

שיעור הבאה בנושא שלילי

Expectation Maximization (EM)

ML (מקסימום likelihood)

נניח שיש לנו זוג של $\chi = \{a_1, \dots, a_n\}$ קבוצת טורים.

ויש לנו מרחב x_1, \dots, x_m (כאשר $x_i \in \mathcal{X}^d$)

פ דגימה, כל קטגוריה עם d כניסות ו- n אמצעי- n התווים.

מחפשים את הפירוק המופיע:

מרחב הפרמטרים
על $(a_{i_1}, \dots, a_{i_d})$
הפונקציה המציינת.

$$\bar{P}_{i_1, \dots, i_d} = \left| \left\{ x_i = (a_{i_1}, \dots, a_{i_d}) : i=1, \dots, m \right\} \right|$$

ס - ML נוצרים לפתור את הבעיה

$$P^* = \operatorname{argmin}_{P \in Q} D(\bar{P} \| P)$$

כאשר $Q = \{q \mid q \geq 0, \|q\| = 1\}$ - קבוצת וקטורים לא שליליים והסתברות

כאשר $P^* = \frac{1}{m} \bar{P} = \hat{P}$ שהסתברות היא

☹

$$Q = \left\{ \sum_{j=1}^k \lambda_j P^j \mid \lambda_j \geq 0, \sum \lambda_j = 1, P^j \in H(\theta_j) \right\}$$

אפשרות של התפלגות עם פרמטרים θ_j

אם Q זו משפחה של קונסטיטנטים θ_j של התפלגות שונה

דוגמה יפה להיות $H = \{N(\mu, \Sigma)\}$ $\theta = (\mu, \Sigma)$ ו- Σ אנוני

אמריקאים של צינפים של התפלגות (נומינל)

$$\theta = u \quad H(\theta) = \{u^{\otimes d} \mid u \in \mathbb{R}^n, \|u\| = 1, u \geq 0\}$$

כל עקב התפלגות בקנה אחד. אפשרות חיצונית - אפשר u קרוב

$$(u^{\otimes d})_{i_1, \dots, i_d} = u_{i_1} \cdot u_{i_2} \cdot \dots \cdot u_{i_d}$$

$d=2$ - עמדת המורה

$$u^{\otimes 2} = u \otimes u = u u^t$$

ואם $u^{\otimes d}$ מהפסד המורה

הוא d פרמטרים

Latent class model

אוגינתיה:

$$p(x_1, \dots, x_d) = \sum_y p(x_1, \dots, x_d | y) p(y) =$$

$$= \sum_{j=1}^k p(x_1, \dots, x_d | y = \alpha_j) p(y = \alpha_j)$$

$y \in \{\alpha_1, \dots, \alpha_k\}$

על y אין לנו מושג ומוא נקרא משתנה חבוי. אפשר לומר ש-

$$p(x_1, \dots, x_d) = \sum_{j=1}^k p(x_1, \dots, x_d | y = \alpha_j) p(y = \alpha_j) =$$

$$= \sum_{j=1}^k \lambda_j p^j \quad (p^j = p(x_1, \dots, x_d))$$

אם מכאן מגיע הנושא שלנו ה-Q - מהסתברות היזמים (על צימוד - למשל מיני התפלגות).

$$H = U^{\otimes 3}$$

צמחה:

- p - ההסתברות של מטבע 1 (הסיכוי שיצא אפס)
- q - ההסתברות של מטבע 2
- g - סיכוי לזכות מטבע 1


אנחנו בוחרים מטבע ואם מטבעים אלו 3 פעמים.
 אם $\{0, 1, 2, 3\}$ מייצג הסדר המטבע שנבחר 3 פעמים.
 ארבע אנחנו אושרים m פרזמים ומקבלים מצבים $\{x_1, \dots, x_m\}$

חשבו וניי שם מה שיש לנו זה המצבים הלכה והמטבע.
 שלנו היא למצב אר g, p, q.
 ההתפלגות האמפירית (ניס)

$$\hat{p}_{i_1, i_2, i_3} = \frac{1}{m} \left| \{x_i = (i_1, i_2, i_3) ; i = 1, \dots, m\} \right|$$

\hat{p} הוא מצוק - באופן $2 \times 2 \times 2$

יש קוביות - צורה



שם קוביות קצת כה מייצגת צורת (3, 2, 1) ונתונה רשם

כמה פעמים הצורה הנתונה הופיעה בצמוד שלנו.

10

$P(X=(i_1, i_2, i_3)) = P$ מה הוסיף כרוח

הצורה $Y=\{1,2\}$ משתנה של צימוד אוליגונומלית הוסיף

$$\Rightarrow P(X=(i_1, i_2, i_3)) = \underbrace{P(X|Y=1)}_{p^{\#0}(1-p)^{3-\#0}} \underbrace{P(Y=1)}_{\lambda} + \underbrace{P(X|Y=2)}_{q^{\#0}(1-q)^{3-\#0}} \underbrace{P(Y=2)}_{1-\lambda}$$

$$= \lambda p^{\#0}(1-p)^{3-\#0} + (1-\lambda)q^{\#0}(1-q)^{3-\#0}$$

מה $Q \ni Q$ של Q היא הקבוצה הסגורה

$$Q = \left\{ \lambda \left(\frac{p}{1-p} \right)^{\otimes 3} + (1-\lambda) \left(\frac{q}{1-q} \right)^{\otimes 3} : 0 \leq p, q, \lambda \leq 1 \right\}$$

מה ה-ML

$$P^* = \underset{0 \leq p, q, \lambda \leq 1}{\operatorname{argmin}} D(\hat{P} \| Q)$$


$$\operatorname{argmin}_y D(x \| y) = \operatorname{argmax}_y \sum_i x_i \log y_i$$

$$\Rightarrow \underset{0 \leq p, q, \lambda \leq 1}{\operatorname{argmin}} D(\hat{P} \| Q) = \underset{0 \leq p, q, \lambda \leq 1}{\operatorname{argmax}} \sum_{0 \leq i_1, i_2, i_3 \leq 1} \hat{P}_{i_1 i_2 i_3} \log \left(\lambda p^{i_1+i_2+i_3} (1-p)^{3-(i_1+i_2+i_3)} + (1-\lambda) q^{i_1+i_2+i_3} (1-q)^{3-(i_1+i_2+i_3)} \right)$$

אוליגונומלית הוסיף (פסודו-היא קלה אולי כי יש פה פונקציה סכומים)

מה האלמנטים EM היא לתקור מלוא סכומים מסומם של צורה של קטגוריות.

מה הקצאת המבנה הוסיף NP-קל אוליגונומלית הוסיף הפיתוח האופטימלי. מה שניתן למצוא לה פתרון סקאלרי. יהיה לנו אלמנטים שמתחבטים על קצות קצוות מקומית.



מה תמונתה הוסיף הוסיף

$$H = \{ u^{\otimes d} : u \in \mathbb{R}^n, u \geq 0, \|u\|_2 = 1 \}$$

$$Q = \left\{ \sum_j \lambda_j u_j^{\otimes d} : \lambda_j \geq 0, \|u_j\|_2 = 1, u_j \geq 0 \right\}$$

$$u = [u_1, \dots, u_k]_{n \times k} \text{ מה } Q = u D u^t \text{ } \forall d=2 \text{ } n$$

$$D = \begin{bmatrix} \lambda_1 & & 0 \\ & \dots & \\ 0 & & \lambda_k \end{bmatrix}_{k \times k}$$

$$u D u^t = \sum_{i=1}^k \lambda_i u_i u_i^t \iff u u^t = \sum_{i=1}^k u_i u_i^t \text{ } \text{שכר}$$

הפציה של Q היא גם היורג k . בואי בחקרה של $d=2$ מתקשים מצד שפירמתו
 עם היורג 2 ונתא הכי קרוב ל- \hat{P} . אם באינרציה היו ידועים היה אפשר
 לפתור אולי עם PCA. עמנו $d > 2$ היצורים הלוא לקראים סבוכים.
 רפויפתנו גר והכזיה ציבן אצטר אר צריגר הסיכור (פריגה של)
 סכנו זה מספר הסיכורים אפריגה 1 שסיכורים אולו סכור. סכני
 אפריגה L זה (u^{od}) , והוכיחו שבו העיה קשה.
 עז כאן הקצמה.

נקודתם סטטיסטי - פיתוח קראס + EM

ML

$$\theta^* = \text{argmax} \log P(x_1 \dots x_m | \theta)$$

יש פתרון x_1, \dots, x_m שגישו ממשתר התפלגות עם פרמטר θ
 ומתקשים אר היתפלגת θ שנותנה אר הנכאר התקטלגיה.
 אקבוצה $\{x_1, \dots, x_m\}$ נתא D . אז

$$\theta^* = \text{argmax} \log \underbrace{\sum_y P(D, y | \theta)}_{P(D | \theta)} = \text{argmax} L(\theta)$$

$$\max L(\theta) = ?$$

$\sum_y q(y | D, \theta) = 1$ - התפלגות שרירותית. בואר $Q(q, \theta)$ נציג פוקציה
 שנקיים $L(\theta) \geq Q(q, \theta) \quad \forall q$

$$L(\theta) = \log \left(\sum_y P(D, y | \theta) \right) = \log \left[\sum_y q(y | D, \theta) \frac{P(D, y | \theta)}{q(y | D, \theta)} \right] \geq$$

יש פה הנחה סמויה שהתסתרו יר צדולג אמל מאפס

$$\left[\text{אוי שוויון Jensen אומר ש-} \log(\sum w_j x_j) \geq \sum w_j \log x_j \text{ כל } w_j \geq 0, \sum w_j = 1 \right]$$

$$\geq \sum_y q(y | D, \theta) \log \left(\frac{P(D, y | \theta)}{q(y | D, \theta)} \right) =: Q(q, \theta)$$

אננו מסוג שלטור אופטימיציה אר זה קר אר מאשר א
 אלה הרמה בין התקטלגיה ל- Q דמסמא ל- L .

11

אם יש לנו $L(\theta) \geq Q(q, \theta)$ בד"כ אנחנו מוצאים

פונקציה Q אשר גורמת איטרציה במהרה $\theta \rightarrow \theta$

ההינח $\theta = \theta^{(t)}$ נהיה q^* כך של $L(\theta^{(t)}) = Q(q^*, \theta^{(t)})$

$$(q^* = \max_q Q(q, \theta^{(t)})) \quad \text{זכור!}$$

$q^* = p(y|D, \theta^{(t)})$ טענה:

$Q(p(y|D, \theta^{(t)}), \theta^{(t)}) =$ הוכחה:

$$= \sum_y p(y|D, \theta^{(t)}) \log \frac{P(D, y | \theta^{(t)})}{P(y | D, \theta^{(t)})} =$$

$$= \sum_y p(y|D, \theta^{(t)}) \log \frac{P(y|D, \theta^{(t)}) P(D|\theta^{(t)})}{P(y|D, \theta^{(t)})} =$$

$$= \log P(D|\theta^{(t)}) \cdot \underbrace{\sum_y p(y|D, \theta^{(t)})}_{=1} =$$

$\log P(D, \theta^{(t)})$ לוג ליקור


$$= \log P(D|\theta^{(t)}) = L(\theta)$$

אז יש לנו את הכור של המסומם כי נמצא $L(\theta) \geq Q(q, \theta)$ -

11) אולי יש לנו זמן - השוני בכל הברת המסומם.

שוב, יש לנו $L(\theta) \geq Q(q, \theta) \quad \forall q$ והינח $\theta = \theta^{(t)}$

$$L(\theta^{(t)}) = Q(\underbrace{p(y|D, \theta^{(t)})}_{q^*}, \theta^{(t)})$$



זרעו של אותנו (מצאים) - האופטימלית הנה אם נרצה אטמיקציה

של Q לפי θ אנחנו נראה וזה הברת זוכה של $L(\theta)$ -

עיה שהצענו - $Q^{(t+1)}$ זרעו (מצא) q^* לפי הנוסחה הטובה

ובנה (משק איטרטיבי)

אם האלמנטים הן רצף:

$$\begin{aligned}\theta^{(t+1)} &= \operatorname{argmax}_{\theta} Q(P(y|D, \theta^{(t)}), \theta) = \\ &= \operatorname{argmax}_{\theta} \sum_y P(y|D, \theta^{(t)}) \log P(D, y | \theta) = \\ &= E_{Y \sim P(y|D, \theta^{(t)})} [\log P(D, y | \theta)]\end{aligned}$$

אם האלמנטים מוצא תחתו ואם מקום אחר.

בשיעור הבא נראה את קרה כאשר x_1, \dots, x_m הם iid
ואם הפונקציה הנה יהיה פשוט יותר ונוכל לעבוד את זה
האופטימיזציה.

לבוא הבא נפגשים ביום שלישי.

EM

הנתונים הם $D = \{x_1, \dots, x_m\} \subseteq \mathbb{R}^d$

$$\theta^* = \operatorname{argmax}_{\theta} \log P(D|\theta) = \operatorname{argmax}_{\theta} \log \sum p(D, y|\theta)$$

← משנה תמי

$$\theta^{(t+1)} = \operatorname{argmax}_{\theta} \sum_Y p(y|D, \theta^{(t)}) \log P(D, y|\theta)$$

אסימנום תהיה אופטימלית
זה עוזר לאנחנו. זה רק אסטרטגיה.

iid הם x_1, \dots, x_m - ע-אנתנו נניח ל- e עצמאית ול- e עצמאית זה יתרון קטן.

$$P(D|\theta) = \prod_{i=1}^m P(x_i|\theta)$$

$$P(D, y|\theta) = \prod_{i=1}^m P(x_i, y_i|\theta) \rightarrow$$

$$P(y|D, \theta) = \prod_{i=1}^m P(y_i|x_i, \theta)$$

ל- e עצמאית זה יתרון קטן.
אם נניח y אחרת זה יתרון קטן.
(הנחה)

$$\Rightarrow \theta^{(t+1)} = \operatorname{argmax}_{\theta} \sum_{y_1, \dots, y_m} \left[\frac{\prod_i P(y_i|x_i, \theta^{(t)})}{P(y|D, \theta^{(t)})} \cdot \sum_i \log P(x_i, y_i|\theta) \right] =$$

$$= \operatorname{argmax}_{\theta} \sum_{i=1}^m \sum_{y_1, \dots, y_m} \alpha(y_i) P(y_i|x_i, \theta^{(t)}) \dots P(y_m|x_m, \theta^{(t)}) =$$

$$= \operatorname{argmax}_{\theta} \sum_{i=1}^m \left[\underbrace{\sum_{y_1} P(y_1|x_1, \theta^{(t)})}_{=1} \underbrace{\sum_{y_2} P(y_2|x_2, \theta^{(t)})}_{=1} \dots \sum_{y_i} \alpha(y_i) P(y_i|x_i, \theta^{(t)}) \dots \underbrace{\sum_{y_m} P(y_m|x_m, \theta^{(t)})}_{=1} \right]$$

(כ' $\sum_x P(x|y) = 1$)

$$= \operatorname{argmax}_{\theta} \sum_{i=1}^m \left[\sum_{y_i} \alpha(y_i) P(y_i|x_i, \theta^{(t)}) \right] =$$

$$= \operatorname{argmax}_{\theta} \sum_{i=1}^m \sum_{j=1}^k P(y_i=j|x_i, \theta^{(t)}) \log P(x_i, y_i=j|\theta)$$

↓
 $y_i \in \{1, \dots, k\}$ (א)

הנתונים אלו הם הסכום הכולל של הסכום קטן יותר.

100) $k=2$ מתחלה זה $P(y_i=2|x_i, \theta^{(t)}) = 1 - w_i^{(t)}$ $w_i^{(t)} = P(y_i=1|x_i, \theta^{(t)})$

$$\max_{\lambda, p, q} \sum_{i=1}^m \left(w_i^{(t)} \log \left[\underbrace{P(x_i|y_i=1, \theta)}_{p^{x_i} (1-p)^{3-x_i}} \underbrace{P(y_i=1|\theta)}_{= \lambda} \right] + (1-w_i^{(t)}) \log \left[\underbrace{P(x_i|y_i=2, \theta)}_{q^{x_i} (1-q)^{3-x_i}} \underbrace{P(y_i=2|\theta)}_{= 1-\lambda} \right] \right)$$

הסכום הכולל של הסכום קטן יותר.

$$= \max_{\lambda, p, q} \overbrace{\sum_{i=1}^m \left(w_i^{(t)} \log[\lambda p^{n_i} (1-p)^{3-n_i}] + (1-w_i^{(t)}) \log[(1-\lambda) q^{n_i} (1-q)^{3-n_i}] \right)}^{(*)}$$

$$P(Y_i=j | X_i, \theta^{(t)}) = \frac{P(X_i | Y_i=j, \theta^{(t)}) P(Y_i=j | \theta^{(t)})}{P(X_i | \theta^{(t)})} = \frac{P(X_i, Y_i=j | \theta^{(t)})}{\sum_j P(X_i, Y_i=j | \theta^{(t)})}$$

המכנה הוא רק אחת מהסתברויות של X_i (כי X_i יכול להיות 1 או 2 או 3). המונה הוא הסתברות של X_i ו- $Y_i=j$ יחד.

$$(**) w_i^{(t)} = \frac{\lambda^{(t)} p^{(t) n_i} (1-p^{(t)})^{3-n_i}}{\lambda^{(t)} p^{(t) n_i} (1-p^{(t)})^{3-n_i} + (1-\lambda^{(t)}) q^{(t) n_i} (1-q^{(t)})^{3-n_i}}$$

$$\frac{\partial \mathcal{L}}{\partial p} = \frac{\sum w_i n_i}{p} - \frac{\sum w_i (3-n_i)}{1-p} = 0$$

: (אזכור א) (*)

$$\Rightarrow (1-p) \sum w_i n_i - p [\sum w_i (3-n_i)] = 0$$

$$\Rightarrow \sum w_i n_i - p [\underbrace{\sum w_i n_i + \sum w_i (3-n_i)}_{3 \sum w_i}] = 0$$

$$\Rightarrow p^{(t+1)} = \frac{1}{\sum w_i^{(t)}} \sum_i w_i^{(t)} \cdot \frac{n_i}{3}$$

$$q^{(t+1)} = \frac{1}{\sum (1-w_i^{(t)})} \sum_i (1-w_i^{(t)}) \cdot \frac{n_i}{3}$$

$$\frac{\partial \mathcal{L}}{\partial \lambda} = \frac{\sum w_i}{\lambda} - \frac{\sum (1-w_i)}{1-\lambda} = 0$$

$$\Rightarrow (1-\lambda) \sum w_i - \lambda \sum (1-w_i) = 0$$


$$\Rightarrow \lambda^{(t+1)} = \frac{1}{m} \sum w_i^{(t)}$$

זכרו שהנתונים $w_i^{(t)}$ יש לנו אותם רק בזמן t . λ, p, q - אלו הם הפרמטרים שאנחנו רוצים למצוא. w_i ? קונסטה (***) בשלבים אלו λ, p, q הם המעודכנים.

מתחילים את התהליך מאמצע (מחול) (התחבתי). $\lambda^{(0)}, p^{(0)}, q^{(0)}$ לקח $\frac{1}{2}, \frac{1}{2}, \frac{1}{2}$.
 אחר כך $w_i^{(0)}$ וכל הנתונים לעדכן את הפרמטרים.

התחננו N - $\log P(D|\theta) = L(\theta)$ וצריך $Q(q, \theta)$ על מנת $L(\theta) \geq Q(q, \theta)$ $\forall q$

$P(y|D, \theta) = q^* = \arg \max Q(q, \theta)$
 $L(\theta) = Q(P(y|D, \theta), \theta)$



יש משפט שמנבא שהתקדמות $L(\theta)$ תהיה הוקרובציה של Q (התקדמות של Q אף התקדמות של L)

Gaussian Mixture

$x \in \mathbb{R}^d$ אנתנו מסתבים θ ומקרה הכי פשוט של גאוסיאן -

$E_j = \sigma_j^2 I$


$P(x) = \sum_{j=1}^k P(x|y=j) P(y=j)$

$N(c_j, \sigma_j^2) = \frac{1}{(2\pi)^{d/2} \sigma_j^d} e^{-\frac{\|x-c_j\|^2}{2\sigma_j^2}}$

המשורה היא מהנימון ממצגם $\{x_1, \dots, x_m\} \subseteq \mathbb{R}^d$ מלבוא או הפרמטרים

$\theta_j = (c_j, \sigma_j^2)$ $\theta = (\theta_1, \dots, \theta_k)$

כה מסנין ראש ה-clustering - אנתנו אר θ_j הפרמטרים של גאוסיאן נושם עקום θ לקובה שאיפה גאוסיאן היא שייכה (יותר גבוהה) - שאיפה גאוסיאן היא שייכה בהסתברות (הכי גבוהה)



(שמשגת EM - רצו לפתור או המקרה

$\sum_j w_{ij} = 1$

$w_{ij}^{(t)} = P(y_i=j | x_i, \theta^{(t)})$ $\lambda_j = P(y=j | \theta)$

$\theta^{(t+1)} = \arg \max_{\substack{x_1, \dots, x_k \\ c_1, \dots, c_k \\ \sigma_1^2, \dots, \sigma_k^2}} \sum_{i=1}^m \sum_{j=1}^k w_{ij}^{(t)} \log[\lambda_j P(x_i | y_i=j, \theta)]$ s.t. $\sum \lambda_j = 1$

ב הסיכוי מה צמוד הקופס

$$\mathcal{L}(\lambda, c, \sigma, \mu) = \sum_i \sum_j [\dots] - \mu (\sum_j \lambda_j - 1)$$

הסדר הנכון הוא

$$\Rightarrow \frac{\partial \mathcal{L}}{\partial \lambda_j} = \frac{\sum_i w_{ij}}{\lambda_j} - \mu = 0 \Rightarrow \lambda_j \mu = \sum_{i=1}^m w_{ij}$$

אין סכוי שלמה
 אלא (זוג) שלם כזה
 איתנו זוגיים דשיר
 דברים האלה האמצע האווה!

$$\Rightarrow \sum_j \lambda_j \mu = \sum_j \sum_i w_{ij}$$

$$\Rightarrow \mu \underbrace{\sum_j \lambda_j}_{=1} = \sum_i \sum_j \underbrace{w_{ij}}_{=1}$$

$$\Rightarrow \mu = m$$

$$\Rightarrow \lambda_j^{(t+1)} = \frac{1}{m} \sum_{i=1}^m w_{ij}^{(t)}$$

כפי שנמשך על זכרון אפי שלם המלמנים, (בשט אה הסיכוי)

$$\log P(x|y=j; \theta) = -d \log \sigma_j - \frac{\|x - c_j\|^2}{2\sigma_j^2}$$

מלמנים רק אה הפרמטרים
 של האונטיים על זכורה

$$\frac{\partial \mathcal{L}}{\partial c_j} = \sum_i \frac{w_{ij}}{\sigma_j^2} (x_i - c_j) = 0$$

$$\Rightarrow \sum_i w_{ij} - \sum_i w_{ij} c_j = 0$$

$$\Rightarrow c_j^{(t+1)} = \frac{1}{\sum_i w_{ij}^{(t)}} \sum_i w_{ij}^{(t)} x_i$$

$$\frac{\partial \mathcal{L}}{\partial \sigma_j} = -\sum_i w_{ij} d \frac{1}{\sigma_j} + \frac{1}{\sigma_j^3} \sum_i w_{ij} \|x_i - c_j\|^2 = 0$$

$$\Rightarrow \frac{1}{\sigma_j^2} \sum_i w_{ij} \|x_i - c_j\|^2 - d \sum_i w_{ij} = 0$$

$$\Rightarrow \sigma_j^{2(t+1)} = \frac{1}{d \sum_i w_{ij}^{(t)}} \sum_i w_{ij}^{(t)} \|x_i - c_j\|^2$$

פונד

מה ה- c_j שמה λ_j (אם)
 $\lambda_j^{(t)} = \frac{P(x_i | y_i = j) P(y_i = j)}{P(x_i)}$

c_j מה

$$w_{ij}^{(t)} = P(y_i = j | x_i, \theta^{(t)})$$

אם נכנסת אש זאטק (פס ארס המונים)
 שלם דחוק מסבום.

נתון: A, B מטריצות $n \times n$ חיוביות. $A \circ B$ הוא המכונה $Q(w, \theta)$ (המכונה $L(\theta)$ אחר-כך).
 $\min D(\hat{P} \parallel \sum \lambda_j P_j)$ s.t. $\lambda \geq 0, \sum \lambda_j = 1, P_j \in H$

נתון: A, B מטריצות $n \times n$ חיוביות. $A \circ B$ הוא המכונה $Q(w, \theta)$ (המכונה $L(\theta)$ אחר-כך).
 נתון: $w^j \geq 0, \sum w^j = 1$. \hat{P} הוא מטריצה $n \times n$ חיובית. $P_j \in H$.

$\min \sum_{j=1}^k D(w^j \circ \hat{P} \parallel \lambda_j P_j)$ s.t. $\lambda \geq 0, \sum \lambda_j = 1, P_j \in H$

כאן $w^j \geq 0, \sum w^j = 1$. \hat{P} הוא מטריצה $n \times n$ חיובית. $P_j \in H$.
 $L(\theta) \leq Q(w, \theta)$ עבור $w \geq 0, \sum w^j = 1$.

$w^* = \arg \min_w Q(w, \theta)$

(*) $w_s^{*j} = \lambda_j P_s^j / \sum \lambda_j P_s^j$

$\Rightarrow L(\theta) = Q(w^*, \theta)$

$\Rightarrow \lambda^* = \arg \min_{\lambda} Q(w, \theta) \Rightarrow \lambda^* = \begin{pmatrix} \|w^1 \circ \hat{P}\|_1 \\ \vdots \\ \|w^k \circ \hat{P}\|_1 \end{pmatrix}$ (**)

EM

$t = 1, 2, \dots$

1) $w^{(t+1)} = (*)$

2) $\lambda^{(t+1)} = (**)$

3) $Q^{(t+1)} = \arg \min_{\theta} D(w^{(t+1)} \circ \hat{P} \parallel \sum \lambda_j^{(t+1)} P_j)$ s.t. $P_j \in H$

התהליך EM הוא שומר על התכונות $w^j \geq 0, \sum w^j = 1$ וכן $P_j \in H$.
 הוא פותר את בעיית המינימום המקומי של $L(\theta)$ באמצעות שיטת EM.




שיטת EM היא שיטה לשיפור אומדן הממוצע של פרמטרים.
 clustering - שיטה לזיהוי קבוצות של נתונים.

אגספון - Clustering

לענו בנושא הזה קרה שהפירנו על נקודה שלקחו מאוסל גאומטרים
 בזורה EM נבדלנו למצב אה הפתורים שלהם ואפי לה נהפנת
 נקודה חדשה ונהנו לשעך מצד גאומטרי היא היגיה

K-means

זה בא גורמים הפשוט ביותר לאגספון. יש אוסל נקודות זמניות
 שיש K אגספון ואנחנו יוצרים את K (זו גם תחילה של
 הגורמים כי בעל זה א כיווילי שיוצרים את אגספון האגספון).
 אנחים של אגספון יש מרכז ואנחנו נוצים אמצוא קטובו
 קואפקטור סגים המרכזים (אזה)



הקטס של התגיה: K-אגספון האגספון
 $x_1, \dots, x_m \in \mathbb{R}^n$ - הנקודות
 $y_1, \dots, y_m \in \{1, \dots, K\}$ - התגיה
 גורמים של הנקודות

אנחנו יש לנו פה בעיה אופטימיזציה:

$$\min_{\substack{y_1, \dots, y_m \\ c_1, \dots, c_K}} \sum_{j=1}^K \sum_{i: y_i=j} \frac{1}{2} \|x_i - c_j\|^2$$

אופטימיזציה אטרנאטין (alternating)

א) נניח c_1, \dots, c_K ידועים. אז (כמו)

$$y_i = \arg \min_j \|x_i - c_j\|^2$$

ב) נניח y_1, \dots, y_m ידועים. אז $S \subseteq \{1, \dots, m\}$

$$\arg \min_c \sum_{i \in S} \frac{1}{2} \|x_i - c\|^2 = \frac{1}{|S|} \sum_{i \in S} x_i$$

$$\frac{1}{2} \|x_i - c\|^2 = \frac{1}{2} (x_i - c)^t (x_i - c) =$$

$$= \frac{1}{2} x_i^t x_i - x_i^t c + \frac{1}{2} c^t c$$

אז אם נבחר ונשווה אגספון (קטס)

$$\sum_i (x_i - c) = |S|c - \sum_i x_i = 0$$

$$\Rightarrow c = \frac{1}{|S|} \sum_i x_i$$

זה מצדדני אלאריה. מתחילים מניחול התחילתי של מרכזים.
 אז אפשר לחשב לפי (1) את התווה. ואז לפי (2) אפשר
 לטעון שכל את המרכזים וככה לחזור על השלבים וסיכומן.
 האלגוריתם הזה תמיד מתכנס למינימום אנרגיה של פונקציה
 האנרגיה.

Spectral Clustering

אנחנו רוצים להשתמש באותה פונקציה אבל שנגיש
 למצב זה פירוק יותר טוב.

נניח את הקבוצה קצת אחרת - (צדד את ψ_1, \dots, ψ_k זהו
 הקבוצות שאנחנו מוגדרים בהן.

$$\min_{c_1, \dots, c_k} \sum_{j=1}^k \sum_{x_i \in \psi_j} \frac{1}{2} \|x_i - c_j\|^2$$

אנחנו יוצרים ל- $c_j = \frac{1}{\ell_j} \sum_{x_i \in \psi_j} x_i$ (גם $\ell_j = |\psi_j|$ צבים ונקטם)

$$\min_{\psi_1, \dots, \psi_k} \sum_{j=1}^k \sum_{x_i \in \psi_j} (x_i^t x_i - 2x_i^t c_j + c_j^t c_j)$$

$$\equiv \min_{\psi_1, \dots, \psi_k} \sum_{j=1}^k \ell_j \cdot \frac{1}{2} \sum_{r, s \in \psi_j} x_r^t x_s - 2 \sum_{j=1}^k \frac{1}{\ell_j} \sum_{r, s \in \psi_j} x_r^t x_s =$$

אפשר לזכור
 $x_i^t x_i$ זה
 כי זהו א
 חשבים על המינימום

$$= \min_{\psi_1, \dots, \psi_k} - \sum_{j=1}^k \frac{1}{\ell_j} \sum_{r, s \in \psi_j} x_r^t x_s$$

$$\equiv \max_{\psi_1, \dots, \psi_k} \sum_{j=1}^k \frac{1}{\ell_j} \sum_{r, s \in \psi_j} x_r^t x_s$$

קיבלנו שזה טוב! במקום ארוכים אוקיידיים קיבלנו מינוס שלטוב
 רק במחיר פנימי יותר. אז אפשר להשתמש ב- Kernel Trick.

$$K = k(x_i, x_j) = \phi(x_i)^t \phi(x_j)$$

$$F_{ij} = \begin{cases} \frac{1}{\ell_r} & x_i, x_j \in \psi_r \\ 0 & \text{אחרת} \end{cases}$$

אם נניח את הנקודות לפי השיק לא שכלול אז F
 נראה אחרת רק:

$$F = \begin{bmatrix} F_1 & & 0 \\ & \ddots & \\ 0 & & F_k \end{bmatrix}$$

$$F_r = \frac{1}{l_r} \begin{bmatrix} 1 & 1 & \dots & 1 \\ \vdots & \vdots & \dots & \vdots \\ 1 & \dots & \dots & 1 \end{bmatrix} \text{ של } l_r$$

$l_r \times l_r$ (מאטריצה) ←

$$\sum_{j=1}^k \frac{1}{l_j} \sum_{r,s} x_r^t x_s = \sum_{i,j} K_{ij} F_{ij} \quad \text{- של } l \text{ (לפי } l \text{)}$$

אלו הן המטריצות המוגדרות

$$\max_F \sum_{i,j} K_{ij} F_{ij} = \max_F \text{tr}(KF)$$

אנחנו רוצים להבנות את F - (המטריצה)

$$G_{ij} = \begin{cases} \frac{1}{\sqrt{l_j}} & x_i \in \psi_j \\ 0 & \text{אחרת} \end{cases} \quad \text{(יציב)}$$

$$g_r = \frac{1}{\sqrt{l_j}} \begin{pmatrix} 0 \\ \vdots \\ 0 \\ 1 \\ \vdots \\ 0 \end{pmatrix} \in \psi_r \quad G = [g_1, \dots, g_k]_{m \times k}$$

$$\Rightarrow g_r g_r^t = \frac{1}{l_r} \begin{bmatrix} 0 & & & \\ & \dots & & \\ & & 1 & \\ & & & \dots & \\ & & & & 0 \end{bmatrix} = \begin{bmatrix} 0 & & & \\ & \dots & & \\ & & F_r & \\ & & & \dots & \\ & & & & 0 \end{bmatrix}$$

$$\Rightarrow \sum_{r=1}^k g_r g_r^t = F$$

של המטריצה G :

$$G^t G = I \quad (4)$$

$$F = G G^t \quad (1)$$

$$G \geq 0 \quad (2)$$

$$\text{לפי } G \geq 0 \text{ ו- } F \text{ סימטרית, } G G^t \mathbf{1} = \mathbf{1} \iff F \mathbf{1} = F^t \mathbf{1} = \mathbf{1} \quad (3)$$

הערה - סכום השורות של F שווה ל-1.

של המטריצה G היא הסימטרית:

$$\text{tr}(KF) = \text{tr}(K G G^t) = \text{tr}(G^t K G)$$

$$\downarrow \\ \text{tr}(AB) = \text{tr}(BA)$$

צ'רק אסתור אלהב'יה \Leftarrow

$$\max_G \text{tr}(G^t K G) \quad \text{s.t.} \quad \begin{aligned} G &\geq 0 \\ GG^t \mathbf{1} &= \mathbf{1} \\ G^t G &= I \end{aligned}$$

נשים זה להב'יה גזוי שקורה זכ'יה של K-means . מסב'ך
 זשני טאן מינפוזציה אלהב'יה על פונקציה האנליזה .

תנאים מספקים: G המשיב'י המקיימ'י אר התנאים

$$G \geq 0, \quad GG^t \mathbf{1} = \mathbf{1}, \quad G^t G = I \quad \text{הן מהצורה}$$

$$G_{ij} = \begin{cases} \frac{1}{\sqrt{|\Psi_j|}} & x_i \in \Psi_j \\ 0 & \end{cases}$$

אנתנו נרצה מצבא אלהב'יה שנומ' קיוב' א פונקציה האנליזה
 גלג' וממס' על ניגוח ספקטראלי .

נסב'י אלהב'יה:

- $G^t G = I$ פירושו של נקודה שייך לאשתו אחד הלב'ך

- $GG^t \mathbf{1} = \mathbf{1}$ נמ' אינ'הו "אוב'ן" שנתן 'וה' בהמשך .

או קורה אמ' צושים ל- G סתמי סטוכסטי' אלא סטוכסטי' רפה'?

$$\max_G \text{tr}(G^t K G) \quad \text{s.t.} \quad \begin{aligned} G &\geq 0 \\ G^t G &= D \\ G \cdot \mathbf{1} &= \mathbf{1} \end{aligned}$$

\uparrow סטוכסטי' \uparrow אלהב'יה

מס'י אנוס' המשיב'י G המקיימ'י $G \mathbf{1} = \mathbf{1}, G \geq 0$

$$G_{ij} = \begin{cases} 1 & x_i \in \Psi_j \\ 0 & \end{cases} \quad \text{הן מהצורה} \quad g_i^t g_j = 0 \quad i \neq j$$

הנחה:

$$0 = \sum_i G_{ir} G_{is} = g_r^t g_s = 0$$

\Leftarrow במ' שורה ל- G יש רק תיוב' אח' ששנה ממס'ם

מהתנאי ל- $G \mathbf{1} = \mathbf{1}$ מקבלים של' הצי'ק אחר' כז'א .



$$GG^t = \begin{bmatrix} \mu^t & & 0 \\ & \ddots & \\ 0 & & \mu^t \end{bmatrix}$$

\Leftarrow

$$\text{tr}(G^t K G) = \text{tr}(K G G^t)$$

$$\Rightarrow \max \text{tr}(G^t K G) = \max \sum_{(i,j) \in \Psi_1} K_{ij} + \sum_{(i,j) \in \Psi_2} K_{ij}$$

$$\equiv \min \sum_{\substack{i \in \Psi_1 \\ j \in \Psi_2}} K_{ij}$$

לא ברור בעיניי min-cut יש קונקציות בגלל זרימה
 זרימה אר הנתק המנומרת. הבעיה כאן היא שיהיה ארוך לפרתק
 מאבד לא מאבד אלא המאבד האולטימטי יתנו את אשכולותם
 מאובתים. אם היינו נוזים לקחת את הבעיה הלא-אובדנים
 זה איבדן מסוים וזה ברור מה שרשם בה עיה המקורית שבה
 יש זרימה נוספת.

כפי שאבדן, ננסה את הבעיה $G^t 1 = \frac{m}{k} 1$ זה אומר שלם
 אשתו יש ברור $\frac{m}{k}$ (קצת קובונו...) ומצד
 $G 1 = 1$ זה נותן $G G^t 1 = \frac{m}{k} 1$.

מהתנאי $G^t G = D$ מקבלים $D = \frac{m}{k} I$ שפירו

$$G^t G = D \Rightarrow G^t \frac{G \cdot 1}{=1} = D \cdot 1 \Rightarrow \frac{G^t \cdot 1}{\frac{m}{k} 1} = D \cdot 1 \Rightarrow D = \frac{m}{k} 1$$

$$\Rightarrow \max_G \text{tr}(G^t K G) \quad s.t. \quad G \geq 0, \quad G G^t 1 = \frac{m}{k} 1, \quad G^t G = \frac{m}{k} 1$$

כיון ש- $\frac{m}{k}$ קטור היא לא משנה את האופטימיזציה וברור יוצא

$$\max_G \text{tr}(G^t K G) \quad s.t. \quad G \geq 0, \quad G G^t 1 = 1, \quad G^t G = 1$$

הבעיה הזו קצת מסוגלת מצי, אך מתקיים אותה (למי בעיניי):

(א) מצא K' סטוכסטיק כפולה בקרובה ביותר ל- K (זרימה) והצורה

מה זה "קרוב ביותר"

$$(2) \text{ פתור את הבעיה } \max_G \text{tr}(G^t K' G) \quad s.t. \quad G^t G = I$$

לא זה שנתנו יוצרים הפתור באמצעות ניתוח ספקטלי.

מהו המספר הגדול ביותר שבו $\max \text{tr}(KGG^t)$ אנחנו נוזים?
 זמנה באסטרטגיה הזאת טובה?
 זמנה יש פה מין משהו פנימי. GG^t תהיה קרובה ל- K כמותן של
 מכפלה פנימית. אז אם נתחיל את K במטריצה צומת שלטו
 סטורוסטי הפעלה א' והתוצאה תהיה GG^t "צומת" ל- K אז GG^t
 "צומת" לסטורוסטי הפעלה.

האינרציה $\sigma \geq 0$ מסתברת לנו גם התיים, אז נתחיל מזה ונקדם משהו
 שאנחנו יוצעים לפעולה. כ- 2 זה כמות מספר זהותם מה אינרציה
 הלה והיתרון של בעיה ספקטריאל היא שאנחנו לא תלויים בניתוח
 התחלתי. אם $K > 2$ יש σ אינרציה אחרת מוצדק עם לה.

Ratio - Cuts

נתחיל $D = \text{diag}(K \mathbb{1})$ $v = (v_1, \dots, v_n)$ $\text{diag } v = \begin{pmatrix} v_1 & & 0 \\ & \ddots & \\ 0 & & v_n \end{pmatrix}$
בעיה: $K - D + I$ סטורוסטי הפעלה הקרובה ביותר ל- K בשלילי
 L_1 (גומר $\|x\|_1 = \sum |x_i|$)

הבעיה: $r = \min_F \|K - F\|_1$ s.t. $F \mathbb{1} = \mathbb{1}, F^t \mathbb{1} = \mathbb{1}$

ל- A מטריצה אלק"ם $\|A\|_1 \geq \|A \mathbb{1}\|_1$ $\|A\|_1 \geq \|A \mathbb{1}\|_1$ $\|A\|_1 \geq \|A \mathbb{1}\|_1$

$\|K - F\|_1 \geq \|(K - F) \mathbb{1}\|_1$

ל- F שלטו ילק"ם

$r \geq \|(K - F) \mathbb{1}\|_1 = \|D \mathbb{1} - \mathbb{1}\|_1 = \|D - I\|_1$

נקדם $F = K - D + I$

$K - (K - D + I) = D - I$

Ⓜ $\|D - I\|_1 = \|K - F\|_1$ \Leftarrow

אם v וז של $D - K$ אם λ אז v וז של $K - D + I$ אם $\lambda - 1$
 האלמנטים אומר לקחת את היות הביקש עם λ שאינו 0 של $D - K$
 וז של יקטן ביותר של $D - K$ נקרא Fiedler Vector והם נומר לנו
 מחוקה לאשכולות. אחר (מספר הבט...)

סכנה בלתי

(1) מצא מטריצה סימטרית כפולה K' (קרוכה ביותר) K
 (2) מצא G : $\max_G \text{tr}(G^t K' G)$ s.t. $G \geq 0$ $G^t G = I$

הצגה: $K' = K - D + I$ כאשר $D = \text{diag}(K \mathbf{1})$ קרוכה ביותר K - השגה L_1

נסה לפתור את ההצגה ללא אילוץ התוספות
 $\max_G \text{tr}(G^t K' G)$ s.t. $G^t G = I$
 נניח v וזו של $D - K$ עם ערך λ . λ \leq λ

$(K - D + I)v = -(D - K)v + v = -\lambda v + v = (1 - \lambda)v$

$\Leftarrow v$ ערך של K' עם ערך $1 - \lambda$
 בודק המובילים של K' הם הודו עם הודו הקטנים ביותר של $D - K$
 (בהתאם מיני שקולים של אצטרוב ליניארי)
 נבחר במקרה $\lambda = 0$. $K = 0$

ברור $\lambda = 0 \Leftarrow D \mathbf{1} - K \mathbf{1} = (D - K) \mathbf{1} = 0$

וזה עם ערך $0 \leq \lambda$. בהתאם G סימטרית הודו שלה אורתונורמלים
 אם v_1 הוא הודו השני של $D - K$ $v_2^t v_1 = 0$ הודו v_2 (קרא
 Fiedler vector . בהתאם $v_2^t v_1 = 0$ - ה- v_2 חייבים להיות

זם זרבים חייבים וגם שליליים . $v_2 \in \mathbb{R}^m$ - ה- v_2 הקואורדינטות
 החיוביות קבועות ו- x_1, \dots, x_m ע"כ Ψ_1 והקואורדינטות
 השליליות קבועות ו- x_1, \dots, x_m ע"כ Ψ_2 .

(ככה למצוא חתך מינימלי) - $\text{cut}(\Psi_1, \Psi_2) = \sum_{\substack{i \in \Psi_1 \\ j \in \Psi_2}} K_{ij}$
 : clustering
 מצא $x \in \mathbb{R}^m$ כך $x^t x = 1$

$\min_x \frac{1}{2} \sum_{i,j=1}^m (x_i - x_j)^2 K_{ij}$ s.t. $x^t x = 1$

אם נפתור את הקואורדינטות של x יקבלו את התחלקה האפשרית .

$$\frac{1}{2} \sum_{i,j} (x_i^2 + x_j^2 + 2x_i x_j) = \frac{1}{2} \sum_i x_i^2 \sum_j k_{ij} + \frac{1}{2} \sum_j x_j^2 \sum_i k_{ij} - x^t K x = x^t D x - x^t K x = x^t (D - K) x$$

→ צריך לפתור את

$$\min_x x^t (D - K) x \quad \text{s.t.} \quad x^t x = 1 \quad (*)$$

קט"ג כללית יותר מאשר בע"ל הפיתרון של

$$\min \frac{1}{2} x^t A x \quad \text{s.t.} \quad x^t x = 1 \quad (A \text{ סימטרית})$$

הוא בעצם מונח על A מה? (אולי):

$$A x - \lambda x = 0 \Rightarrow A x = \lambda x$$

$$\Rightarrow \frac{1}{2} x^t A x = \frac{1}{2} x^t \lambda x = \frac{1}{2} \lambda x^t x = \frac{1}{2} \lambda$$

אם λ הוא הערך המינימלי

→ הפיתרון של (*) הוא הו"ע הכי קטן (באם של"ק אר"ע הכי קטן)

על $D - K$. את הו"ע הזה מוצאים על ידי Matlab

גם $G = (V, E)$ גרף מכוון. מטריצה חולה של G היא

$$B = \begin{bmatrix} 1 & & \\ 0 & \dots & \\ -1 & & 0 \end{bmatrix}_{|V| \times |E|}$$

1 מונח קטל' ו-1 מונח קטל' אחר

מקיים $B B^t = D - K$ כאשר K מטריצה הסימטרית קצרה

normalized cuts

$$D = \text{diag}(k_1) \quad \text{אשר} \quad K' = D^{-1/2} K D^{-1/2}$$

אם (U, A, B) תהיה פתרון של בעיית הקט"ג

$$K^{(0)} \leftarrow K$$

$$D^{(0)} \leftarrow \text{diag}(K)$$

$$K^{(t+1)} \leftarrow (D^{(t)})^{-1/2} K^{(t)} (D^{(t)})^{-1/2}$$

$$D^{(t+1)} \leftarrow \text{diag}(K^{(t+1)})$$

→ כאשר $K^{(t)}$ הוא מטריצה סימטרית

הפכה הקרובה ביותר ל- K שיש לה אנשים יחסית

מתבוננים בהם, הבעיה היא למצוא את המטריצה K' כך ש $K' = D^{-\frac{1}{2}} K D^{-\frac{1}{2}}$ והיא סימטרית וריבועית.

נוצרים מטריצה G כך ש $G^t G = I$

$$\max_G \text{tr}(G^t (D^{-\frac{1}{2}} K D^{-\frac{1}{2}}) G) \quad \text{s.t.} \quad G^t G = I$$

מה שמציינים אנחנו היא ה"א הישני (ע) $D^{-\frac{1}{2}} K D^{-\frac{1}{2}}$

נסתם את האלמנטים

$$\text{cut}(A, B) = \sum_{i \in A} \sum_{j \in B} K_{ij}$$

לצורך תחביר $A \cap B = \emptyset, A, B = V$

$$\text{sum}(V_1, V_2) = \sum_{i \in V_1} \sum_{j \in V_2} K_{ij}$$

$$\Rightarrow \text{cut}(A, V-A) = \text{sum}(A, V) - \text{sum}(A, A)$$

$$N \text{cuts}(A, B) = \frac{\text{cut}(A, B)}{\text{sum}(A, V)} + \frac{\text{cut}(A, B)}{\text{sum}(B, V)}$$

הכנסו את המטריצה K ואת A, B ואת V ואת $V-A$

$$N \text{assoc}(A, B) = \frac{\text{sum}(A, A)}{\text{sum}(A, V)} + \frac{\text{sum}(B, B)}{\text{sum}(B, V)}$$

$$\Rightarrow N \text{cuts}(A, B) = 2 - N \text{assoc}(A, B)$$

$$\Rightarrow \min N \text{cuts}(A, B) \equiv \max N \text{assoc}(A, B)$$

$$\max_{\Psi_1, \dots, \Psi_k} N \text{assoc}(\Psi_1, \dots, \Psi_k) = \max \sum_{j=1}^k \frac{\text{sum}(\Psi_j, \Psi_j)}{\text{sum}(\Psi_j, V)}$$

$$\bar{G} = [g_1, \dots, g_k]$$

$$g_j = \frac{1}{\sqrt{\text{sum}(\Psi_j, V)}} \begin{pmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{pmatrix} \Psi_j$$

$$\Rightarrow g_j^t K g_j = \frac{1}{\text{sum}(\Psi_j, V)} \cdot \sum_{r \in \Psi_j} K_{r,r}$$

$$\text{tr}(\bar{G}^t K \bar{G}) = \sum_j g_j^t K g_j = N \text{assoc}(\Psi_1, \dots, \Psi_k)$$

$$g^t D g = \frac{1}{\text{sum}(\Psi_j, v)} \cdot \sum_{r \in \Psi_j} d_r = \frac{1}{\text{sum}(\Psi_j, v)} \cdot \sum_r \sum_s K_{r,s} =$$

$$= \frac{\text{sum}(\Psi_j, v)}{\text{sum}(\Psi_j, v)} = 1$$

$$\Rightarrow \bar{G}^t D G = I$$

$$G^t G = I \iff G = D^{-1/2} \bar{G} \quad (\text{נרציב})$$

נרציב את $\bar{G} = D^{-1/2} G$ בקציה שלנו ונקבל

$$\max_G \text{tr}((D^{-1/2} G)^t K (D^{-1/2} G)) \quad \text{s.t.} \quad G^t G = I$$

המתקנה של v_1 הוזה בטענה (היא) $v_1 = D^{-1/2} \cdot 1$ למעשה

$$(D^{-1/2} K D^{-1/2}) D^{-1/2} \cdot 1 = D^{-1/2} K \cdot 1 =$$

$$= \begin{bmatrix} \frac{1}{\sqrt{d_1}} & & \\ & \ddots & \\ & & \frac{1}{\sqrt{d_m}} \end{bmatrix} \begin{bmatrix} d_1 \\ \vdots \\ d_m \end{bmatrix} = D^{-1/2} \cdot 1$$

בואו $D^{-1/2} \cdot 1$ ו"ע עם $\lambda = 1$

הוקטור הזה שוב לא מניח אינפורמציה. הישני, הישן שלם אורתוגונלי. אנו זוכים תיוב"ם ושלבים למצוא את השיטה אחרת. פשוט.

יש לנו יותר משני איטנורים. צריך להתמודד עם $G \geq 0$. יש שני שיטות להתמודד עם זה. בט אפן הקציה הוא קטן - קשה!

בשלב הבא נתון למספר יפיו של שיטותיו תלוי - 'ומשני' ושלשי

השלבים הקרובים (משך זמן) אופיים גרפיים

ניפגש ביום שלישי הבא.

Graphical Models מודלים גרפיים

היינו צריכים את ההצגה ואם היישובים שלה רחב מאוד
 המרחב יותר מציפי. השיעור הבא נביא דוגמה של מרחב כוחות.
 המרחב של אנטון יש קישורים למרחבים אחרים דוגמת קוונטים בנושאים.

ף

עד היום התבוננו בשיעור של התפלגות. התקרה הפשוט
 הייתה של התפלגות אחת. התקרה הייתה מורכבת של ציורים
 סימנים של התפלגות פתחני את EM.

האופטים לזכרון יצורה התפלגות ורובים לזכרון אחת
 מקוונט. לנייה ש- $\{k, \dots, n, x_i\}$ ויש לנו $P(x_1, \dots, x_n)$
 לנייה שרובים אמצעים את $\max_{x_1, \dots, x_n} P(x_1, \dots, x_n)$
 אם רוצים לזכרון את P יש פה בעיה תופש את n^k
 מצבים שלה התבה.

דוג דוגמה כזו כשפוצים זה שלב או $p(x_i) = \sum_{x_1, \dots, x_n} P(x_1, \dots, x_n)$
 זו סכימה של n^k איברים וזה התבה.

גבולות: לנייה $R(\theta|x) = \sum_{\theta} l(\theta, \theta) p(\theta|x)$ ורובים
 $\theta^* = \min_{\theta} R(\theta, x)$ זמנצווא
 $l(\theta, \theta) = \begin{cases} 0 & \theta = \theta^* \\ \infty & \text{אחרת} \end{cases}$ מקבלים
 $\theta_{MAP}^* = \arg \max_{\theta} P(\theta|x)$

לזכרון $l(\theta, \theta) = (\theta - \theta^*)^2$ מקבלים
 $\theta_{MUSE}^* = \sum_{\theta} \theta p(\theta|x)$

אם לא - המוסטריציה מבינה

אנחנו רוצים להגדיר -

$$P(x_1, \dots, x_n) = \frac{1}{Z} \prod_{\alpha} \psi_{\alpha}(x_{\alpha})$$


$\psi_{\alpha} \geq 0$; $x_{\alpha} \notin \{x_1, \dots, x_n\}$; $\alpha \notin \{1, \dots, n\}$; כל ψ_{α}

$$P(x_1, \dots, x_6) = \frac{1}{Z} \psi_1(x_1) \dots \psi_6(x_6) \psi_{124}(x_1, x_2, x_4) \psi_{236}(x_2, x_3, x_6) \psi_{135}(x_1, x_3, x_5)$$

אם שמות האותיות הם כמו שהיו של ψ היא מוקצית של פונקציה
משמשים אותה למתחילת וזה פשוט יותר לגיבור
אם הצורה של ψ מתארת היחס.

השיטה הכללית היא קריאת factor graph

זה גרף עם ציבוי שיש לו 8 קצוות, 3 צמתים
צמתי משתנים (variable nodes) 3 צמתים
למשתנים α - 1.



יש קשר בין צמתים α וצמתים x אם α מכיל את x .


האקרה $\psi_i(x_i) = \phi(x_i)$ אם $i \in \alpha$

אם $\psi_i(x_i) = \phi(x_i)$ ו- x_i הוא hidden node
אם $\psi_i(x_i) = \phi(x_i)$ ו- y_i הוא observation node


אם $\psi_i(x_i) = \phi(x_i)$ ו- x_i הוא hidden node
אם $\psi_i(x_i) = \phi(x_i)$ ו- y_i הוא observation node

$$p(x_1, \dots, x_n | y_1, \dots, y_n) = \prod_i p(x_i | y_i) \cdot \prod_{\alpha} \psi_{\alpha}(x_{\alpha})$$

$$= \prod_i \phi_i(x_i) \quad (|d_i| > 1)$$



יש צורך מייצג את כל הנתונים בלבד
 של המאמרים הקודמים α . נבחרת שלנו



ההצגה הזאת לא נראתה כשקולנו
 נעשה אפילו יותר זמן כפי
 אנוסים זה נראה וקרי-צפוי

המתח שלנו בתים הוא אנוסים
 הקורא את הסימונים x ו- x^* הם
 נונים הם שמה של הנתון
 מתחם שמהם אנוסים זה הנתון והוא יתרון
 יש אנוסים BP שונים אנוסים הנתון והוא אנוסים

מחפשים . אפשר להבין את האלגוריתם אם לא ברור
 שיש בו מחפשים אם לא כמובן להבין שיש צורך
 אם מותר שיהיה הפורמטור המעניין - הן עם גימטרים
 התחום היה די ארוך המשק כ- 10 שנים ואז (הוא קם
 למתיה זה התקרה של אשור שלקראו turbo codes
 זה עזר אר התחום אחד עם התחולו אמתה אלגוריתמים
 מחקרים שמנסה שיתכנסו גם במקרה שיש מחפשים .

אפשריך ממון פורמטור שלמתחילתו ומה רצוני לפתור
 אר הפסיה של חושב $P(x)$.

Linear Codes נתחם הזה factor graph
 (קרא tunnel graph)

נויגל - $x_1 \dots x_n$ שזה הפסיה של ה-code word
 ψ_2 הן ה- parity checks :

$$\psi_2 = \begin{cases} 1 & \sum x_i = 0 \pmod{2} \\ 0 & \text{אחר} \end{cases}$$

3. ! (123) הפורמטור שלנו יש 3 ביטים שלמחציה עקב
 ביטים בשלבי ה parity check (456)
 אר יש 4 הוצרור חוקיה :

הוצרור	}	0 0 0 0 1 1 1 1
		0 0 1 1 0 0 1 1
		0 1 0 1 0 1 0 1
parity	}	0 0
		0 1
		0 1

אם הוצרור + ה parity שלב
 $G = \begin{bmatrix} I_{n \times k} \\ P_{(n-k) \times k} \end{bmatrix}$

למשל , במקרה שלנו
 $P = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix}$ $P(x) = \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix}$

נניח $r = S = G$ באשר S הרוצה r , G הרוצה r .
 הרוצה השלחה. ההצטרף r ציבוק אנשים S .
 הקציה היא שיש רחש בשליחה. אצל אנשים $r = G = S$.
 ראש r של אבא.

אם מה שמעניין אותנו הוא

$$p(x_1 \dots x_n | y_1 \dots y_n) = \prod p(x_i | y_i) \prod \psi_\alpha(x_\alpha)$$

 מהנחה שהביטים מסתי תלויים אלה מסלה (כזו הנחה סבירה).
 עמה כופלים ב- $\psi_\alpha(x_\alpha)$ כי יש הוצאות שיהיה זכיר שלפניו תקיור הכלל ואז ה- $\psi_\alpha(x_\alpha)$ יתאים או זה.


אם היינו מתלבים או $p(x_i) = p(x_i=0)$ ומהלך היינו מקבלים code-word מתוקן - היינו מתלבים 0 או 1 בהתאם לרובות ההבדלה יותר.

אפשר גם לחשב את $\arg \max_{x_1 \dots x_n} p(x_1 \dots x_n | y_1 \dots y_n)$ אולם צומרי שהאנלוגיות שמתלבה זה בחור מפוקק אלה למחלה או $p(x_i)$.

צומרי ל- BP בנוב המקרים מתכנס כל זה עיה הנרא ונות הוצאה קרובג מאוד עמה שרכון. אלא שינוי זהיוו של code word וקצ' עמו חוקי יאצ ציבוק אפסל מהנאם.

Stereopsis יש שג' אחונה מוסר קצ' -

אנשים מקבל תמונה סמוך



על וקודה P_i מוצאים את הנקודה המתאימה P_i' והתוצאה היחסית שלהן (disparity) פרופורציונלית לעומת

מציאת ההתאמה $P_i \leftrightarrow P_i'$
 אצל $\phi_i(x_i) =$ סיכוי לעצם גרסאות x_i של סוג התאמה
 גאומטרית

ההנחה שההתאמה נמצאת באותו ישר עוברת על סגור
 ויש הצדק ואישים קונבולוציה. וקודה המנסים את הקונבולוציה
 מראשית אצל התוצאה. יקרה כי יש המון המון
 נקודות שאינם עשויים וזאת עובד.

נסו $\psi_{ij}(x_i=r, x_j=s) = e^{-|r-s|}$

שקיים $\psi_{ij}(x_i, x_j) = \begin{bmatrix} 1 & \dots & 1 \\ \vdots & & \vdots \\ 1 & \dots & 1 \end{bmatrix}$

$$p(x_1, \dots, x_n) = \prod_{i=1}^n \phi_i(x_i) \prod_{(i,j) \in K} \psi_{ij}(x_i, x_j)$$

המטריצה ψ_{ij} מתאמת ממוצגר לפקסטים שכתוב
 והיוצאים לה עבר

הסיכוי לפקסטים לריוג הם אותה $n-n$ ה-disparities

$$p(x_i) = \begin{pmatrix} p(x_i=1) \\ \vdots \\ p(x_i=n) \end{pmatrix}$$

וכאן משתמשים ב-BP

Super Resolution

יש גמנה. אם משתמשים אלה
 מתחיל לריוג שטוס. היינו חוצים למלא את הטקסט
 וזה באינפורמציה. נצטרך מלא גמנות שההקבלתה היא
 בהנחה של המצלמה. נכפ יוצא שלב פיקסלים ויש נמה צמיחה
 ורק אפשר להקטין את הרזולוציה. זה סופר-רזולוציה ווקר
 אצל מה אתה בעל זוג יש יק גמנה אתה

23) נניח שהתמונה שלנו בארה מאפשרת מסוימת של תמונה (זאת) רק נניח או רק ברזורים.

נניח יש לנו תמונה 500×500 שרזורים 100×100 - 500×500 נסתכל על מצגת איחון של תמונה באופן 100×100 ונצטרך לרדוק $down\ sampling$ ל- 500×500 .

אנחנו נסתכל על טבלאים בגודל קטן $\sqrt{500 \times 500}$ (נניח 25×25) ונראה שהם עברו קרינה של תמונה שלנו. הטבלאים 10×10 הכי קרוב אליו מבין אמצע התמונה שיש לנו. אלא שצריך יותר עיבוד אי-רזורים - התמונה.

נניח שהטבלאים הם x_1, \dots, x_n ונניח $\{x_1, \dots, x_n\}$ אחרת רזורים אחר.

$$p(x_i) = \begin{pmatrix} p(x_i = 1) \\ \vdots \\ p(x_i = 16) \end{pmatrix}$$

אם i - $p(x_i)$ גיקה בתלסקון $\psi_{ij}(x_i, x_j) = e^{-d(x_i, x_j)}$ אם נחפיר $\psi_{ij}(x_i, x_j)$ $\psi_{ij}(x_i, x_j)$ $\psi_{ij}(x_i, x_j)$


$$p(x_1, \dots, x_n) = \prod_i \phi_i(x_i) \left(\prod_{j \in N(i)} \psi_{ij}(x_i, x_j) \right)$$

$= e^{-d(x_i, y_i)}$ ייצג אחרות

אם כן פותרים בעזרת BP והתוצאה יוצאת ממש טוב! (אמרו: Freeman, Jones, Pastor 2002)

Image Editing (cho, יופי - 08 CVPR)

יש תמונה שיש בה אובייקט כלשהו ורוצים להעביר אותו למקום אחר בצורה שיהיה כמות רזורים שהיא זהה יוצאת טוב!



שיטת רזורים אחרת - שיטת רזורים אחרת

X_1, \dots, X_n נתון אחרת מנתון לא תופסים

$i, j = 1, \dots, n$ מקומות השניים θ_i ו- θ_j

$$\theta_i(x_i) = \begin{pmatrix} \theta_i(x_i=1) \\ \vdots \\ \theta_i(x_i=n) \end{pmatrix} - \text{נכנסים אלוף של המשתנה}$$

כאשר, אם נוצר להצטרף את θ_i ו- θ_j מקום k

$$\begin{cases} \theta_i(x_i=k) = 1 \\ \theta_i(x_i \neq k) = 0 \\ \theta_j(x_j=l) = e^{-(j-l)^2} \end{cases}$$

ששאר
הפסגים ילדו
סתור או צור
אפק שליו במקור

כמה ציפוי לרצף: $\Psi_{ij}(x_i, x_j) = e^{-\frac{|x_i - x_j|}{\text{מרחק}}}$ סה"כ


$$p(x_1, \dots, x_n) = \prod_i \theta_i(x_i) \prod_{(i,j) \in E} \Psi_{ij}(x_i, x_j) \underbrace{E(x_1, \dots, x_n)}_{\text{מקומות } \theta_i}$$

ה- E זהה פתאום שלטו יהיו חורים - של θ_i ו- θ_j עובר למקום אחר ושובר נוצרם למחברים באן את $p(x_i)$ כדי להתאים את לקחה לא.

רשת ביסואניו

פיזיאולוגיה רפואית - יש סמטות, הפקול והתולו
ולס סתק ב הקלפים יש נוצרם למחברים

צילום "שפה" (Lauritzen 1988)



24


$P(X_i | \text{par}(X_i))$ זה קלט רשום
הסיכוי של X_i בהינתן ההורים שלו.

$$P(X_A \dots X_D) = \prod_i P(X_i | \text{par}(X_i)) =$$

$$= P(X_A) P(X_S) P(X_2 | X_S) P(X_B | X_S) P(X_E | X_T, X_C) P(X_D | X_B, X_E)$$

$P(X_D) = ?$ ויטואלים

מאופן בלי X_i מאבי רשום בהשתיי שלמים שלמים "ודציק"
של X_i בהינתן ההורים שלו. $X_i \perp Z_i | \text{par}(X_i)$ (נמו)



$X_1 \perp X_2$

$X_4 \perp \{X_1, X_2, X_5\} | X_3$

$X_5 \perp \{X_2, X_3, X_4\} | X_1$

$$P(X_1 \dots X_5) = P(X_1) \underbrace{P(X_2 | X_1)}_{= P(X_2)} P(X_3 | X_1, X_2) \underbrace{P(X_4 | X_1, X_2, X_3)}_{= P(X_4 | X_3)} \underbrace{P(X_5 | X_1, X_2, X_3, X_4)}_{P(X_5 | X_1)}$$

ההיסקה האיתור

הרשם ההיסטוריה מתארת את האותיות
בין המשתנים ומתייחס ליוצאים או ההתפלגויות הנותני
ואלה שנוצרים למשל זה או ה marginals $(P(X_i))$.

קלוא ס"מ"ו אג (התחבול)
והתחבול ב"ו

קשור המסל נפתח את BP ופאזר הפך נכאה תוממים
יותר מופתים...

ניכאש היום שני ג-800


25) 25/03/08
 → ציור/תמונה

ציורים (הצגות)


ה- notes-heaven יורד ציורים מסוג זה
 של עיבודי דטה מסקום ממנו.

$$P(x_1, \dots, x_n) = \frac{1}{Z} \prod_{\alpha} \Psi_{\alpha}(x_{\alpha}) \quad \underline{BP}$$


היא אפוא את המצב הזו:



ה- BP חוקיות (הצגות) בין הציורים



מיו 1:



מיו 2:

$$m_{\alpha \rightarrow i}(x_i) = \sum_{x_{\alpha} | x_i} \Psi_{\alpha}(x_{\alpha}) \prod_{j \in N(\alpha) \setminus i} n_{j \rightarrow \alpha}(x_j)$$

ההוצאות מתחילת הציורים:

$$n_{j \rightarrow \alpha}(x_j) \equiv 1$$

(1) אם היה מסו מסתובב

$$m_{\alpha \rightarrow j}(x_j) = \sum_{x_{\alpha} | x_j} \Psi_{\alpha}(x_{\alpha})$$

(2) אם היה מסו α מסתובב

זכיון ב צומ שולח בוצה אחת שקיבלה א
 ב ההוצאה מהשנים שפא אליהם היא חוזרת לשלוח

אחרי שב צומ קיבלה אגב מה שיש לה לקבל
 ושלחה אגב מה שיש לה לשלוח האלמנטים (יחיד)
 אם יצורה קהל האלמנטים יוצרי, ואם יש אלמנטים
 אלו היא יוצרי

$$P(x_i) \cong \prod_{\alpha \in N(i)} m_{\alpha \rightarrow i}(x_i) \quad \text{יחיד}$$

שורה זו כפי
 מכילה מקדים

$$P(x_\alpha) = \sum_{\{x_1, \dots, x_n\} | x_\alpha} P(x_1, \dots, x_n) = \psi_\alpha(x_\alpha) \prod_{i \in N(\alpha)} m_{i \rightarrow \alpha}(x_i)$$

אם ב ההוצאה בתכנסו און אזיה מתלב א
 מה שצריך

הסיבוכיות תלויה בצורה של היצירות - זה
 אלמנטים אופטימלי מתוך סיבוכיות אגב נכון
 כאש ויק כאש הגוף הוא של


$$P(x_\alpha) = b_\alpha(x_\alpha) \quad ; \quad P(x_i) = b_i(x_i) \quad \text{מסומנים}$$

אם האל אל אל האלמנטים יבול לפרט אגב א
 תכונה התוצאה שלו

זה אלמנטים אוב ויצור שקל לתכנה, אגב
 שבו התכונות המצוינות יש אגב אלמנטים
 אלו אגב אגב אגב

26

תוצאה:



קבוצת משתנים
 קבוצת משתנים
 קבוצת משתנים
 קבוצת משתנים

הסתברות המשותפת היא:

$$P(X_1, \dots, X_{11}) = \psi_{\alpha_3}(X_7, X_5, X_6) \psi_{\alpha_1}(X_1, X_2, X_5) \psi_{\alpha_2}(X_3, X_4, X_6) \\
 = \psi_{\alpha_4}(X_7, X_8, X_9) \psi_{\alpha_5}(X_{10}, X_{11}, X_8)$$

נחשב את $p(X_7)$ ונראה שזה שווה ל- $p(X_7)$

נרצה להשתמש:

$$Z_{\alpha_3|7} = \{X_1, X_2, X_3, X_4, X_5, X_6\} \\
 Z_{\alpha_4|7} = \{X_8, X_9, X_{10}, X_{11}\}$$

קבוצת משתנים
 (כאשר X_7 נתון)

$$F_\alpha(x_i, z_{\alpha i}) = \prod_{\beta \in \text{pa}(x_i)} \psi_\beta(x_\beta)$$

מכאן נראה כי המכונה של המכונה α היא ψ_α

$$\Rightarrow F_{\alpha_3}(x_7, z_{\alpha_3 7}) = \psi_{\alpha_3}(\cdot) \psi_{\alpha_1}(\cdot) \psi_{\alpha_2}(\cdot)$$

$$F_{\alpha_4}(x_7, z_{\alpha_4 7}) = \psi_{\alpha_4}(\cdot) \psi_{\alpha_5}(\cdot)$$

$$\Rightarrow P(x_1, \dots, x_n) = F_{\alpha_3}(x_7, z_{\alpha_3 7}) \cdot F_{\alpha_4}(x_7, z_{\alpha_4 7})$$

$$P(x_7) = \left(\sum_{z_{\alpha_3 7}} F_{\alpha_3}(x_7, z_{\alpha_3 7}) \right) \left(\sum_{z_{\alpha_4 7}} F_{\alpha_4}(x_7, z_{\alpha_4 7}) \right)$$

כאן נראה כי המכונה $m_{\alpha_3 \rightarrow 7}(x_7)$ היא $\sum_{z_{\alpha_3 7}} F_{\alpha_3}(x_7, z_{\alpha_3 7})$

$$- m_{\alpha_3 \rightarrow 7}(x_7) = \sum_{z_{\alpha_3 7}} F_{\alpha_3}(x_7, z_{\alpha_3 7})$$

$$- m_{\alpha_4 \rightarrow 7}(x_7) = \sum_{z_{\alpha_4 7}} F_{\alpha_4}(x_7, z_{\alpha_4 7})$$

$$\sum_{z_{\alpha_3 7}} F_{\alpha_3}(x_7, z_{\alpha_3 7}) = \sum_{x_{\alpha_3}} \psi_{\alpha_3}(x_{\alpha_3}) \prod_{\alpha \in \text{pa}(x_{\alpha_3})} \psi_\alpha(x_\alpha) =$$

$$= \sum_{x_{\alpha_3} | x_7} \psi_{\alpha_3}(x_{\alpha_3}) \sum_{\substack{j \in N(\alpha_3) \\ j \neq 7}} \left[\prod_{\alpha \in N(j) | \alpha_3} \psi_\alpha(x_j, z_{\alpha j}) \right] =$$

$$= \sum_{x_{\alpha_3} | x_7} \psi_{\alpha_3}(x_{\alpha_3}) \prod_{j \in N(\alpha_3) | j \neq 7} \underbrace{\prod_{\alpha \in N(j) | \alpha_3} \psi_\alpha(x_j, z_{\alpha j})}_{m_{\alpha \rightarrow j}(x_j)}$$

אם כן נראה כי המכונה של המכונה α היא ψ_α ונראה כי המכונה $m_{\alpha \rightarrow j}(x_j)$ היא $\prod_{\alpha \in N(j) | \alpha_3} \psi_\alpha(x_j, z_{\alpha j})$ ונראה כי המכונה $m_{j \rightarrow \alpha_3}(x_j)$ היא $\prod_{\alpha \in N(j) | \alpha_3} \psi_\alpha(x_j, z_{\alpha j})$


27

$$P(x_1, \dots, x_n) = \prod_{i=1}^n \theta_i(x_i) \prod_{\alpha} \psi_{\alpha}(x_{\alpha})$$

$$n_{i \rightarrow \alpha}(x_i) = \prod_{\beta \in N(i) \setminus \alpha} \theta_{\beta}(x_i)$$

$$m_{\alpha \rightarrow i}(x_i) = \sum_{x_{\alpha}} \psi_{\alpha}(x_{\alpha}) \prod_{j \in N_{\alpha}(i)} \theta_j(x_j) n_{j \rightarrow \alpha}(x_j)$$

$$P(x_i) = \prod_{\alpha \in N(i)} m_{\alpha \rightarrow i}(x_i) \theta_i(x_i)$$



אז ככה נגדנו (קראו את ה- θ) והוא היסטורי
 משהו ה-80. זהו (אולי) דוגמה של θ וזה
 מובנה.

הוא זה המובנה "ב" - מוקד את ה- θ אוטומטי
 הניסוח הוא זהו קטן אוטומטי.

$$P(x) = \frac{1}{Z} \prod_{\alpha} \psi_{\alpha}(x_{\alpha})$$

מנסים להפיק b^*

$$\min_b D(b \| \prod_{\alpha} \psi_{\alpha}(x_{\alpha})) \Rightarrow b^*(x) = P(x) = \frac{1}{Z} \prod_{\alpha} \psi_{\alpha}(x_{\alpha})$$

$b \geq 0$
 $\|b\|_1 = 1$

שה (זהו) מנסים להפיק b^* - $\|b\|_1 = 1$

$$D(b \| \prod_{\alpha} \psi_{\alpha}(x_{\alpha})) = \sum_{\alpha} \sum_{x_{\alpha}} E_{\alpha}(x_{\alpha}) b_{\alpha}(x_{\alpha}) - H(b)$$

$- \ln \psi_{\alpha}(x_{\alpha})$

זה קראו free energy

אם הממוצע הכובד עם זהו מנסים האם יוכלו
 מנסים מנסים $H(b)$ זהו אקספוננציאל
 אם המנסים הוא מנסים קיובק מנסים מנסים
 אולי מנסים מנסים.

$$P(x_1, \dots, x_n) = \frac{\prod_{\alpha} P(x_{\alpha})}{\prod_{i=1}^n P(x_i)^{d_i-1}} \quad \text{פרט: } \underline{1 \text{ כנס } 0}$$

x_i כנס $\alpha \rightarrow N(i) \rightarrow \text{מס} = d_i$ יעד

צדק

$H(P) = H_{\text{Mather}}(P)$ ↓ המקרה של P

$$= \sum_{\alpha} \sum_{x_{\alpha}} P(x_{\alpha}) \log P(x_{\alpha}) - \sum_i (1-d_i) \sum_{x_i} P(x_i) \log P(x_i) =$$

$$= \sum_{\alpha} H(P_{\alpha}) + \sum_i (1-d_i) H(P_i)$$

זרעו המוכנה (אם לא קיימת צימוד) אלא תוסף
 על הקליפה המגוימת.

Bethe free energy

$$\text{Min}_b \sum_{\alpha} \sum_{x_{\alpha}} E_{\alpha}(x_{\alpha}) b_{\alpha}(x_{\alpha}) - \sum_{\alpha} H(b_{\alpha}) - \sum_i (1-d_i) H(b_i)$$

s.t.

$$\sum_{x_{\alpha} \ni x_i} b_{\alpha}(x_{\alpha}) = b_i(x_i) \quad \forall \alpha \in N(i)$$

$$b \geq 0$$

$$\sum_{x_{\alpha}} b_{\alpha}(x_{\alpha}) = 1 \quad \forall \alpha$$

2005 (צ'צ'יה, פרימן, ו' 0 2005) : וקליפה של $b_i(x_i), b_{\alpha}(x_{\alpha})$ למשל Bethe free energy
 BP על

הקליפה

Bethe free energy, פרט ①

marginals \rightarrow e \rightarrow מ'מ'מ'מ' \rightarrow s \rightarrow \rightarrow

Bethe free energy, פרט ②

(28)

יש אלגוריתמים שפותחים כסדר על ידי מחיצאים חניונים
סיקטרי (KCCP) אבל הם מאוד מאוד מסובכים
אם זה לא תבס.

בזמן של אש פתא כנסו של רצובים פורשים -
אז אם לפתור את הבזוק לעצבים האם ייתן קירוב
של הפיתרון הנכון (tree reweighted)
הכיוון הישרי זכני הוא Convex free energy

שיעור תורה:

10-14

29/4

סקור רמא איך שיעורים

אם $\lambda = \infty \Leftrightarrow \sum p_i = 1$ וקיימים תוצאה הייחודית: ההסתברות הן יחס הופך את הריבוי המצוי.

הצורה: הכתה ראיון ככה שלה שמה שאומר
 מצא. המבחן מצופה מאינו לפרט או
 לה מתחיל.

שאלה 2

ML קצח

$$f(x | \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma x} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}$$

צגה התפלגות log-normal והיא די אינטרס -
 אלו הן זהות קצת, אלו הטכניקה

$$\max_{\theta} \log p(x_1, \dots, x_m | \theta) =$$

$$= \max_{\theta} \prod_{i=1}^m f(x_i | \mu, \sigma) =$$

$$= \max_{\mu, \sigma} \sum_{i=1}^m \left[\log \left(\frac{1}{\sqrt{2\pi}\sigma x_i} \right) + \log \left(e^{-\frac{(\log x_i - \mu)^2}{2\sigma^2}} \right) \right]$$

$$= -\frac{m}{2} \log 2\pi - m \log \sigma - \sum_{i=1}^m \log x_i - \sum_{i=1}^m \frac{(\ln x_i - \mu)^2}{2\sigma^2}$$

אין אינדיקס אך פשוט (רצוי וישווה) אפס:

$$\frac{\partial}{\partial \mu} = \frac{1}{\sigma^2} \cdot \sum_{i=1}^m (\ln x_i - \mu) = 0 \Rightarrow \mu = \frac{1}{m} \sum_{i=1}^m \ln x_i$$

$$\frac{\partial}{\partial \sigma} = -\frac{m}{\sigma} + \frac{1}{\sigma^3} \sum_{i=1}^m (\ln x_i - \mu)^2 = 0 \Rightarrow \sigma^2 = \frac{1}{m} \sum_{i=1}^m (\ln x_i - \mu)^2$$

שאלה 3

מטרת התרגיל היא לשאול קוביות - אחת הוצגה והשנייה תמיד נופלת על פאה "1".

אם צצים ניסוי 3 פעמים: מסיים מטרת - אם H אז מסיים קוביה הוצגה. אחרת, הקוביה השנייה ננית לקיבולנו "111".

מה הסיכוי שהמטרה תושלם? HHH
ההסתברות כמות המתי תלויה. אם

$$P(HHH | 111) = P(H|1)^3$$

- זרשיו נשמע בנוסחה כ"ס

$$P(H|1) = \frac{P(1|H) \cdot P(H)}{P(1)} = \frac{\frac{1}{6} \cdot \frac{1}{2}}{\frac{1}{6} \cdot \frac{1}{2} + 1 \cdot \frac{1}{2}} = \frac{1}{7}$$

$$\Rightarrow P(HHH | 111) = \frac{1}{7^3}$$

שאלה 4

שאלה תשוב שיש להבין היטב. קשה למנהיג גופים מתמטי!

$$\min \frac{1}{2} w^t w \quad \text{s.t.} \quad y_i (w^t x_i) \geq 1 \quad y_i = \pm 1$$

b=0 SVM שלם זו הע"ר

ridge-regression אנתני (פתור) אר כ"ר

$$\min \frac{1}{2} w^t w + \sum (y_i - w^t x_i)^2$$

נימ: גורמים לרג האופן שקודם:

$$\min \frac{1}{2} w^t w + \sum \epsilon_i^2 \quad \text{s.t.} \quad \epsilon_i = y_i - w^t x_i$$

זוה נשלבו שינוי קר (פתור)

(השום לא הוטרנספון)

$$\mathcal{L} = \frac{1}{2} w^t w + \sum_i \epsilon_i^2 + \sum_i \lambda (y_i - w^t x_i - \epsilon_i)$$

$$\frac{\partial \mathcal{L}}{\partial w} = w - \sum x_i x_i = 0 \Rightarrow w = \sum x_i x_i$$

כל w הוא קומבינציה של וקטורים x_1, \dots, x_m ונקראת

$$\frac{\partial \mathcal{L}}{\partial \epsilon_i} = 2\epsilon_i - \lambda_i = 0 \Rightarrow \epsilon_i = \frac{1}{2} \lambda_i$$

$$w = Q \cdot \lambda \quad \text{כל} \quad Q = [x_1 \dots x_m] \quad (N \times M)$$

(צירוף מה לקיסטנו הטרנספון)

$$\mathcal{L} = \frac{1}{2} \lambda^t Q^t Q \lambda + \frac{1}{4} \sum_i \lambda_i^2 - \frac{1}{2} \sum x_i^2 +$$

$$+ \sum x_i y_i - \lambda^t Q^t Q \lambda =$$

$$= -\frac{1}{2} \lambda^t Q^t Q \lambda - \frac{1}{4} \lambda^t \lambda + \lambda^t y$$

כל מה שהיה הצואה והאותה אנתנו הרים מסתם

$$\frac{\partial \mathcal{L}}{\partial \lambda} = -Q^t Q \lambda - \frac{1}{2} \lambda + y = 0$$

$$\Rightarrow \lambda = (Q^t Q + \frac{1}{2} I)^{-1} y$$

$$\Rightarrow w = Q \lambda = Q (Q^t Q + \frac{1}{2} I)^{-1} y$$

בהינתן x (N) כל y :

$$y = w^t x = y^t (Q^t Q + \frac{1}{2} I)^{-1} Q^t x$$

מה קיסטנו? (אם לא רגורסיה רשימו ב- y מה צואה ונקראת ...)

31

5 (a)

צורת קומבינציה של שתי התפלגויות log-normal:

$$g(x) = \lambda f(x | \mu_1, \sigma_1) + (1-\lambda) f(x | \mu_2, \sigma_2)$$

נתונים: x_1, \dots, x_m - ערכי x ו- δ - פרמטרים $\mu_1, \sigma_1, \mu_2, \sigma_2$

יש סך משתנה מסווג y שאומר אם הצטיחה (הייתה) $N(\mu_1, \sigma_1)$ או $N(\mu_2, \sigma_2)$ - סוג

$$P(x_1, \dots, x_m) = \sum_y P(x_1, \dots, x_m | y) P(y)$$

הצטיינות הן iid ונתתי מוקדם הנחה זו:

$$\theta^{(t+1)} = \max_{\theta} \sum_{i=1}^m \underbrace{P(y_i=1 | x_i, \theta^{(t)})}_{w_i^{(t)}} \log \left[\underbrace{P(x_i | y_i=1, \theta)}_{f(x_i | \mu_1, \sigma_1)} \underbrace{P(y_i=1 | \theta)}_{\lambda} \right] + \sum_{i=1}^m \underbrace{P(y_i=2 | x_i, \theta^{(t)})}_{1-w_i^{(t)}} \log \left[\underbrace{P(x_i | y_i=2, \theta)}_{f(x_i | \mu_2, \sigma_2)} \underbrace{P(y_i=2 | \theta)}_{1-\lambda} \right]$$

נפתח את זה ונתקלם גם זה של קטור הפרמטרים, נבדוק את הכתובים ויפול להגדרה של ציבור אסתטי.

$$\max_{\theta} \left[\sum w_i^{(t)} \left[\log \lambda - \log \sigma_1 - \frac{1}{2\sigma_1^2} (\log x_i - \mu_1)^2 \right] + \sum (1-w_i^{(t)}) \left[\log(1-\lambda) - \log \sigma_2 - \frac{1}{2\sigma_2^2} (\log x_i - \mu_2)^2 \right] \right]$$

$$\frac{\partial}{\partial \lambda} = \sum_i \left[\frac{w_i^{(t)}}{\lambda} - \frac{(1-w_i^{(t)})}{1-\lambda} \right] = 0$$

הזרה השניה: במקרה הכללי אסור לשכוח את

האינול $\sum \lambda_i = 1$

ε λλθ)

$$\frac{1}{\lambda} \sum_i w_i^{(t)} - \frac{1}{1-\lambda} \sum_i (1-w_i^{(t)}) = 0$$

$$\Rightarrow (1-\lambda) \sum w_i^{(t)} - \lambda \sum (1-w_i^{(t)}) = 0$$

$$\Rightarrow \sum w_i^{(t)} - \lambda [\sum w_i^{(t)} + \sum (1-w_i^{(t)})] = 0$$

$$\Rightarrow \lambda^{(t+1)} = \frac{1}{m} \sum w_i^{(t)}$$

∴ 0"ב λλθ) וס'כרסן וס'כרסן w_i אכ

$$w_i^{(t+1)} = p(y_i=1 | x_i, \theta^{(t+1)}) =$$

$$= \frac{p(x_i | y_i=1, \theta^{(t+1)}) p(y_i=1 | \theta^{(t+1)})}{p(x_i | \theta^{(t+1)})} =$$

$$= \frac{\phi(x_i | \mu_1^{(t+1)}, \sigma_1^{(t+1)}) \lambda^{(t+1)}}{\phi(x_i | \mu_1^{(t+1)}, \sigma_1^{(t+1)}) \lambda^{(t+1)} + \phi(x_i | \mu_2^{(t+1)}, \sigma_2^{(t+1)}) (1 - \lambda^{(t+1)})}$$




הסתתן ק' - אין טר'יק'ס'!

אם י'ר'ס' אכ ה'ת'ו'ר א'ק'ס'ים 100

1) מופתם S $h(x) = \text{sign}(w^t x + b)$

$$\gamma = \min_i \left\{ \frac{y_i (w^t x_i + b)}{\|w\|} \right\}$$

2) הגרעק המקסימלי בין שתי פאימור - תיכור ושלילי
 היא $\frac{l}{2}$. (נפת מראן ל- $\gamma \leq \frac{l}{2}$ ותוצה אנו
 כי אם הנחישו הנפרים מאונק אישע מין הוקרור ו
 אלה אצ השל של $\frac{l}{2}$ ואם היא לא מאונק
 אצ השל קטן מ- $\frac{l}{2}$.



מאופן יור פורמלי :

$$l = d_+ + d_-$$

$$\gamma \leq \min(d_+, d_-) \leq \frac{l}{2}$$

3) יש מרחב \mathbb{R}^n עם הוקרור - x_1, \dots, x_m ואל

מהכרה ניתנו מהפרזה מין ארו -
 אנתנו זוקתים א הוקרור מרחב \mathbb{R}^{n+m} ו
 אנתנו רוצים שהן תהינה ניתנו מהפרזה.
 גרור העתקה מאופן הבא :

$$x_i \mapsto (x_i^1 \dots x_i^n \underset{\substack{\uparrow \\ \text{מקום } n+i}}{0} \dots 0 \ 1 \ 0 \dots 0) = x_i'$$

למה המופתם החצט S' נותק מהפרזה?
 כי אם תויל ניקח $w = [0 \dots y_1 \dots y_m]$ ואצ $w^t x_i' = y_i$

אם g המפריד לקיימנו \mathbb{R}^{n+m} (תצור תלרה \mathbb{R}^n - \mathbb{R}^m)
 אין שום ההטחה של y עקוב של \mathbb{R}^{n+m} אל \mathbb{R}^n ולכן
 זה לא הטוח ניתן להפריד, אמל:

$$\begin{matrix} & + & & + \\ + & - & - & + \\ & + & - & + \\ - & + & - & + \end{matrix}$$

(4) גזר $K(x, y) = x^t y$

צריך להגדיר K' רק של הפעולה האלימנטרית
 S' (של \mathbb{R}^{n+m} אל \mathbb{R}^n - x אל \mathbb{R}^n - \mathbb{R}^{n+m} ואל \mathbb{R}^n)
 מפעיל עליו אם S שיוצא להפריד וקודם ניתן
 להפריד) אם K תהיה שקולה להפעיל
 האלימנטרית S על K' .
 אם S בטוח (גזר)

$$K'(x_i, x_j) = \begin{cases} x_i^t x_j & i \neq j \\ x_i^t x_{j+1} & i = j \end{cases}$$

2005 כ' אלה 1

יש וקטור $x_1, \dots, x_m \in \mathbb{R}^d$ ו $m > d$ ומרוצים עליון
 PCA רק שיוצא $\hat{x} = uu^t x$ האל

u התקבל n - PCA. נתון $\|u\| = 1$.
 נתלב את $\|x - \hat{x}\|^2$.

מתקיים $x = \hat{x} + (x - \hat{x})$ מהאלימנטרית מתקבל
 $\hat{x} \perp x - \hat{x}$ במק

$$\|x\|^2 = \|\hat{x}\|^2 + \|x - \hat{x}\|^2$$

$$\Rightarrow \|x - \hat{x}\|^2 = 1 - \|\hat{x}\|^2 =$$

$$= 1 - \|uu^t x\|^2 = \|u^t x\|^2$$

כ u אורתונורמלי

VC-dim(H1 ∩ H2) ≤ min(VC-dim(H1), VC-dim(H2)) : ד' צ' 1

ממא VC גים המספר הנקסיות d רק שיש d נקלפון שניתן להשיג את 2^d גיוגים או היפוגור N - H.

ד' צ' d = min(VC1, VC2) וניתן להשיגה ש- VC-dim(H1 ∩ H2) > d

כ' d = VC1

VC-dim(H1 ∩ H2) > VC-dim(H1)

קיימור d+1 נקלפון רק שיש 2^{d+1} גיוגים אשלפיים אינו היפוגור ג- H1 ∩ H2 אלא אם כן H1 ג- H1 דם מת'יג d+1 נקלפון כ' היפוגור ג- VC-dim(H1) = d לה בסתירה ד' רק ש-

2) הפוגמטור ג' ריוניאליור קן טלש H1 = H2 או H1 ⊆ H2

3) יפוג ש- π_H(m) ≤ (e m / d)^d

ממא VC של H יפוי H1, H2 מת'קור ג' היפוגור כ' ש- VC-dim(H1) = VC-dim(H2) = 1 ד' רק ד' הרוא ש- VC-dim(H1 ∪ H2) < 5

מתקיים π_H1(5), π_H2(5) ≤ e · 5

ניתן ש- VC-dim(H1 ∪ H2) = d ש' ש' d נקלפון רק ש' א' א' א' 2^d היפוגור H1 יורה מת' ד' היור ed תיגים ו' H2 דם ס' H1 ∪ H2 יורה מת' ד' היור

ed תיאור d - d הוקדשו ולה להכרה
 $ed \geq 2^d$. (בצדק אר ב ה) - d -ים האפליים
 הראשון שלה לא מתקיים עבורו (לאו) התוס
 פנח.

2004 א' שאלה 6

זאג שאלה קטנה אך התשובה היא פשוט
 PCA - פילי פירמית.

2005 א' שאלה 2

① ברור. הירפנו אר err ואר err .

② צדיק לחר צומחה למחמה מצמח X עם פילוח

\mathcal{D} ווקדשו x_1, \dots, x_m יק \mathcal{L} -

$$err(h) \geq \frac{1}{2} \quad err(h) = 0$$

$h \in C$ היפומה

ניקח $X = \mathbb{R}$ ופילוח סלסל - וניה גאוס'אנג
 H - יכולה לחר ל תויה על וקודה ארע
 שמקבלים איזלסל מצמח פליו ניק אר התשובה
 הוכנה על א שלא במצמח ניק גלובה ורונה
 גרסתברור $\frac{1}{2}$ - טומר הטלר מטכ.

③ צומחה (ידיית לה) מצמח הוספיל הקצמ.


מה לא נרונ בהורחה של ורשלה? ברעם שבוחים
 היפומלו - תוק הסתלויל על המצמח מטכ היפדינג
 היררר עא נכונ.

④ הורחנו בתוקלו

34

1 אלה 2007

1) אם יש 3 נקודות בהכרח יש שתיים שהלוחית ביניהן שווה ל-180° כלומר (תייג) אולם ה- (+) ו- (-) השלישי ה- (-) או אולי אחרת:



2) $a, b \in \mathbb{R}$ עבור $K(a, b) = (1 + ab)^2$ (אולי) (אולי) K -על פונקציה גורעין: יקח $\varphi(a) = (1, \sqrt{2}, a, a^2)$

1 אלה 2007

1) K_1, \dots, K_n (positive semi definite) PSD $K = \sum \alpha_i K_i$ כל $\alpha_i \geq 0$ ו- $d_1, \dots, d_n \geq 0$

$$v^t K v = v^t \sum \alpha_i K_i v = \sum \alpha_i \underbrace{v^t}_{\geq 0 \text{ וגון}} \underbrace{K_i v}_{\geq 0 \text{ כי PSD}} \geq 0$$

אולי

2) $w \in \mathbb{R}^n$ יהי H מישור w -ר (הניצב) $H = \{z : w^t z = 0\}$

$$d(x, H) = \min_{z \in H} \|z - x\|$$

$$d(x, H) = \frac{|w^t x|}{\|w\|} \quad : \text{ג}$$

למשל, נכתוב את התנאי:

$$\min_z \|z - x\|^2 \quad \text{s.t.} \quad w^t z = 0$$

כתיבה אחרת של התנאי היא $w^t z = 0$.

$$\mathcal{L}(z, \lambda) = (z - x)^t (z - x) + \lambda w^t z$$

$$\frac{\partial \mathcal{L}}{\partial z} = 2z - 2x + \lambda w = 0$$

$$\Rightarrow z = x - \frac{\lambda}{2} w$$

$$\Rightarrow w^t (x - \frac{\lambda}{2} w) = w^t x - \frac{\lambda}{2} w^t w = 0$$

$$\Rightarrow \lambda = \frac{2 w^t x}{\|w\|^2} \Rightarrow z^* = x - \frac{w^t x}{\|w\|^2} w$$

$$\Rightarrow \|z^* - x\| = \left\| x - \frac{w^t x}{\|w\|^2} w - x \right\| =$$

$$= \frac{|w^t x|}{\|w\|^2} \cdot \|w\| = \frac{|w^t x|}{\|w\|}$$