

סדר	8	7	6	5	4	3	2	1

מבחן מועד א' – מבוא ללמידה חישובית סמסטר א' תשע"ד (2013)

בית הספר למדעי המחשב, אוניברסיטת תל-אביב

מרצים: פרופ' ערן הלפרין, פרופ' ליאור וולף, פרופ' ישי מנצור,

מתרגל: מריאנו שיין

30.1.2014

הוראות

1. מומלץ לקרא את כל ההנחיות והשאלות בתחילת המבחן, לפני תחילת כתיבת התשובות.
2. משך הבחינה – **שלוש שעות**. לא תינתן כל הארכה נוספת.
3. חומר עזר מותר: **ללא**.
4. **יש לענות על השאלות במקום המיועד לכך בטופס השאלון (טופס זה)**. מחברות הבחינה לא ייקראו, וישמשו כטייטה בלבד.
5. יש למלא בכל דף של השאלון מספר ת.ז. ומספר מחברת.
6. במבחן 8 שאלות:
 - הניקוד לכל שאלה מופיע לידה מספר השאלה.
 - יש לענות תשובות ברורות ענייניות ותמציתיות.
7. מותר להשתמש בכל טענה שהוכחה בכיתה (בהרצאה, בתרגול, או בתרגיל בית) בתנאי שמצטטים אותה במדויק. טענות אחרות (כאלה שהוכחו בספר, בהרצאות מהסמסטר הקודם, וכו') יש להוכיח.
8. אם לא נאמר אחרת, יש להניח שדגימות במדגם נוצרות באופן בלתי תלוי ומאותה התפלגות (i.i.d)

בהצלחה!

שאלה 1 (10 נקודות).


נתונים האלגוריתמים הבאים

א. עץ החלטה עם decision stubs (כלומר $x_i > a$ עבור כל מימד i וקבוע a)

ב. SVM עם Gaussian kernel

ג. מסווג מסוג 1-NN (NN=Nearest Neighbor)

נתון מדגם דו-מימדי הבא, בו שני סיווגים \star ו- \circ




עבור כל אחד מהאלגוריתמים מרצים אותו עד שמקבלים מסווג עם שגיאת למידה אפס (על המדגם)

קבעי/האם האלגוריתם יגיע לשגיאה אפס. אם לא הסבר מדוע. אם כן צייר קו הפרדה מתאים למסווג המתקבל:

א. עץ החלטה עם decision stubs (כלומר $x_i > a$ עבור כל מימד i וקבוע a)

לא יכול להגיע לשגיאה אפס. הסבר _____

יכול להגיע לשגיאה אפס. קו הפרדה של המסווג:




תעודת זהות:

מספר מחברת:

ב. תוכנית SVM עם Gaussian kernel

לא יכול להגיע לשגיאה אפס. הסבר _____


יכול להגיע לשגיאה אפס. קו הפרדה של המסווג:



ג. מסווג מסוג 1-NN (NN=Nearest Neighbor)

לא יכול להגיע לשגיאה אפס. הסבר _____

יכול להגיע לשגיאה אפס. קו הפרדה של המסווג:



שאלה 2 (10 נקודות).

נתונה בעיה עם קלט של 3 משתנים בינאריים, $x_1, x_2, x_3 \in \{0,1\}$, ופלט בינארי $y \in \{0,1\}$

1. עבור מסוג המניח מודל הסתברותי Naïve Bayes כמה פרמטרים צריך לשערך מהנתונים? (רק את המספר)

7

2. עבור מסוג במודל הסתברותי כללי (ללא הנחת אי התלות של Naïve Bayes) כמה פרמטרים צריך לשערך מהנתונים? (רק את המספר)

16

שאלה 3 (10 נקודות).

בכל אחת מהשאלות הבאות יש לבחור את היחס המתאים בין הכמות המתוארת במשפט הראשון (א) לכמות המתוארת במשפט השני (ב). למשל, אם (א) גדול מ (ב) יש לבחור באפשרות הראשונה גדול . כמו כן יש להסביר בקצרה את הבחירה.

בתוחלת על המדגם שנבחר:

- א. ממוצע השגיאה על המדגם שעליו נבחרת ההשערה ע"י ERM
ב. ממוצע השגיאה על דוגמאות שלא ראינו של ההשערה שנבחרת ע"י ERM.

גדול קטן שווה לא ניתן לדעת

הסבר:

כיוון שביצענו מינימיזציה של השגיאה ב-ERM גרמנו ל- $overfitting$.
כיוון שמדובר בתוחלת על המדגם אין "מדגם רע".
בהינתן מדגם S יש השערה $h(S)$ -ש-ERM מחזיר.
על מדגם חדש T תוחלת השגיאה היא בדיוק השגיאה של T .
על S כיוון שבחרנו את ההשערה שהביאה למינימום, התוחלת קטנה יותר.

מידת ה- $overfitting$ זה הפרש בין ממוצע השגיאה על המדגם והסתברות השגיאה:

- א. מידת ה- $overfitting$ כשלאלגוריתם הלמידה ERM יש 100 השערות לבחירה
ב. מידת ה- $overfitting$ כשלאלגוריתם הלמידה ERM יש 200 השערות לבחירה

גדול קטן שווה לא ניתן לדעת

הסבר:

ככול שיש יותר השערות מידת ה- $overfitting$ תגדל
דרך את לראות את זה, זה דרך חסמי הכללה למחלקה סופית.

לכן אם m קבוע, אם מגדילים את H אזי ϵ צריך לגדול.

שאלה 4 (15 נקודות).

נתון מדגם בגודל m מהצורה $(x_{i,1}, x_{i,2}, y_i)$, ובו נתונים דו-מימדיים (x_1, x_2) ופלט y .

רוצים לבצע רגרסיה כך: $y = w^2 x_1 + x_2$

א. יש להגדיר את פונקציית המטרה של הרגרסיה (עבור שגיאה ריבועית):

ב. יש חשב את w שמביא למינימום את פונקציית המטרה שהוגדרה בסעיף א:

$$W^{2*} = \max \left\{ 0, \frac{\sum_{i=1}^m x_{i,1} (y_i - x_{i,2})}{\sum_{i=1}^m x_{i,1}^2} \right\}$$

החישוב:

$$\frac{d}{dw} \sum_{i=1}^m (w^2 x_{i,1} + x_{i,2} - y_i)^2 = \sum_{i=1}^m 2w x_{i,1} (w^2 x_{i,1} + x_{i,2} - y_i) = 0$$
$$w = 0 \text{ or } w \neq 0 \text{ and } \sum_{i=1}^m x_{i,1} (w^2 x_{i,1} + x_{i,2} - y_i) = 0$$

שאלה 5 (12 נקודות).

מריצים SVM על בעייה מסויימת, ואז מריצים פעם שנייה, כאשר את הנקודה הראשונה לוקחים פעם אחת, על הנקודה השנייה חוזרים פעמיים, על השלישית שלוש פעמים וכן הלאה.

האם הפתרון בפעם השנייה יהיה שונה מזה של הפעם הראשונה:

א. עבור SVM ליניארי עם HARD MARGIN

כן לא הסבר:

כיוון שחייבים לקיים את כל האילוצים, ובודקים את ה-margin לפי המקרה הגרוע לכן אין משמעות לשכפול הנקודות.

ב. עבור SVM עם HARD MARGIN עם קרנל גאוסני

כן לא הסבר:

כיוון שחייבים לקיים את כל האילוצים, ובודקים את ה-margin לפי המקרה הגרוע לכן אין משמעות לשכפול הנקודות.

ג. עבור SVM ליניארי עם SOFT MARGIN

כן לא הסבר:

כיוון שלא חייבים לקיים את כל האילוצים, שגיאה בנקודה ראשונה שווה חצי משגיאה בנקודה השנייה, ולכן פתרון האופטימיזציה יכול להשתנות.

ד. עבור SVM עם SOFT MARGIN עם קרנל פולינומיאלי מדרגה שנייה

כן לא הסבר:

כיוון שלא חייבים לקיים את כל האילוצים, שגיאה בנקודה ראשונה שווה חצי משגיאה בנקודה השנייה, ולכן פתרון האופטימיזציה יכול להשתנות.

תעודת זהות:

מספר מחברת:

שאלה 6 (15 נקודות).

עבור תוכנית AdaBoost הנח שההשערה החלשה שנלמדת h_t בעלת שגיאה ϵ_t
עבור כל אחד מהערכים של ϵ_t קבע איזה משקל תקבל ההשערה h_t והסבר מדוע זה סביר

א. $0.5 = \epsilon_t$

$\alpha_t = 0$

הסבר (למה זאת בחירה הגיונית מעבר לכך שזה מה שהאלגוריתם מבצע):

אם השגיאה חצי אזי אנו לא רוצים להתחשב בהשערה

ב. $0 = \epsilon_t$

$\alpha_t = \infty$

הסבר (למה זאת בחירה הגיונית מעבר לכך שזה מה שהאלגוריתם מבצע):

אם להשערה אין שגיאה בכלל אנו רוצים תמיד להשתמש רק בה

ג. $1.0 > \epsilon_t > 0.5$

$\alpha_t = \ln \frac{1 - \epsilon_t}{\epsilon_t}$

הסבר מה מיוחד בתחום הזה (ולמה זאת בחירה הגיונית מעבר לכך שזה מה שהאלגוריתם מבצע):

המקדם יוצא שלילי וזה הגיוני כיוון שהמינוס של ההערה יש שגיאה טובה מחצי.

שאלה 7 (15 נקודות)

בכל תא בטבלה למטה ציינו האם תוצאת האלגוריתם תשתנה כתוצאה מהפעלת הטרנספורמציה המצוינת. נמקו את תשובתכם בקצרה. תוצאת האלגוריתם – ניבוי התוויות של דוגמאות חדשות שעוברות כמונן את אותה טרנספורמציה.

x_0 הוא וקטור. a הוא סקלר שונה מאפס. U מטריצה יוניטרית ($U^t U=I$). A היא מטריצה ריבועית מדרגה מלאה. (הכל במספרים ממשיים).

<p>Hard margin linear SVM</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: אם הפתרון היה w ו-b לאחר הטרנספורמציה נקבל w $b-w^t x_0$ אותה נורמה של w</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: אם הפתרון היה w לאחר הטרנספורמציה נקבל w/a בתור פתרון לכל w אנו מחלקים אתהנורמה ב- a^2</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: הקרנל הליניארי נותר ללא שינוי ולכן הבעיה הדואלית זהה.</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: אם יש פחות נקודות מהמימד, ניתן עם A להגיע מכל בעיה לכל בעיה אחרת באותו מספר של נקודות חיוביות ושליליות</p>
<p>K Nearest Neighbor, $k=3$</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: המרחקים לא משתנים</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: המרחקים יוכפלו, אבל שכנויות לא ישתנו</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: המרחקים לא משתנים</p>	<p><input type="checkbox"/> תשתנה <input type="checkbox"/> לא תשתנה הסבר: אם יש פחות נקודות מהמימד ניתן להגיע ע"י A מכל בעיה לכל בעיה אחרת עם אותו פיזור של תוויות (נקודות בקונפיגורציה כללית)</p>

שאלה 8 (13 נקודות).

עבור $\theta \sim U[0,1]$, $X|\theta \sim N(\theta, 1)$ נתון מדגם מ X בעל דגימה בודדת x

א. מהו משערך ML עבור θ

$$\theta_{ML}^* = \begin{cases} 1 & \text{for } x > 1 \\ x & \text{for } x \in [0,1] \\ 0 & \text{for } x < 0 \end{cases}$$

הסבר:

$$L = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x-\theta)^2}{2}\right)$$

$$\ell = -(x-\theta)^2/2 + \text{const}$$

$$\frac{d\ell}{d\theta} = -(x-\theta) = 0 \rightarrow \theta = x$$

צריך לשמור את $\theta \in [0,1]$

ב. מהו משערך MAP עבור θ

$$\theta_{MAP}^* =$$

הסבר: עבור ההתפלגות האחידה הפתרון זהה לסעיף א כיוון שהצפיפות של ה-prior היא 1

צריך לשמור את $\theta \in [0,1]$