

## מבוא ללמידה חישובית – מבחן מועד א' סמסטר א' תשע"ו (2015/6)

בית הספר למדעי המחשב, אוניברסיטת תל-אביב

מרצים: פרופ' ליאור וולף, פרופ' ערן הלפרין  
מתרגל: רגב שוייגר


26.1.2016

### הוראות:

1. מומלץ לקרוא את כל ההנחיות והשאלות בתחילת המבחן לפני תחילת כתיבת התשובות.
2. משך הבחינה – **שלוש שעות**.
3. חומר עזר מותר: דף נוסחאות בגודל A4.
4. יש לענות על השאלות במקום המיועד לכך בטופס השאלון (טופס זה). מחברות הבחינה לא תקראנה, ותשמשנה כטיוטה בלבד.
5. יש למלא בכל דף של השאלון מספר ת.ז. ומספר מחברת.
6. במבחן 5 שאלות:
  - הניקוד לכל שאלה מופיע ליד 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.).

## 1 שאלה 1 - 20 נקודות

נתון המדגם הדו־מימדי הבא, בו הנקודות מסווגות לשתי מחלקות:




עבור כל אחד מהאלגוריתמים הבאים, קבע/י האם ניתן להריץ אותו עד לקבלת מסווג עם שגיאת למידה אפס, על המדגם הנתון. אם כן, צייר/י קו הפרדה מתאים למסווג המתקבל. אם לא, הסבר/הסבירי מדוע.

1. עץ החלטה, כאשר ה־classifiers מתוכם האלגוריתם בוחר הם כל ה־decision stumps המקבילים לצירים (כלומר, עבור כל מימד  $i$ , וסף  $a$ , ניתן לבחור class-sifier שמסווג על פי תוצאת השוואה  $x_i < a$ ).

לא יכול להגיע לשגיאה אפס. הסבר:


יכול להגיע לשגיאה אפס. קו הפרדה של המסווג:



2. 1-Nearest Neighbor, כאשר הנקודה הנבדקת לא נכללת ברשימת הנקודות השכנות.

לא יכול להגיע לשגיאה אפס. הסבר:


יכול להגיע לשגיאה אפס. קו ההפרדה של המסווג:



3. SVM עם Gaussian kernel.

לא יכול להגיע לשגיאה אפס. הסבר:

יכול להגיע לשגיאה אפס. קו ההפרדה של המסווג:



## שאלה 2 - 20 נקודות

ראינו שהאלגוריתם של בעיית הרגרסיה הלינארית, מוצא פתרון אופטימלי ביחס לפונקציית ה-L2 loss. כעת נגדיר פונקציית loss חדשה, הנותנת לכל נקודה משקל שונה. כלומר, ה-loss על תחזית  $\hat{y}_i$  של הנקודה ה- $i$  יהיה:

$$L_i(\hat{y}_i, y_i) = w_i \cdot (\hat{y}_i - y_i)^2$$

1. מהי פונקציית האופטימיזציה המתאימה לבעיה החדשה?

תעודת זהות:  
מספר מחברת:

---

2. האם המשקולות יכולות לשנות את הפתרון הנמצא, ביחס לבעיה המקורית ללא המשקולות? אם כן, תנאי דוגמה. אם לא, הוכיח/י.

### שאלה 3 - 20 נקודות

האלגוריתם שראינו בכיתה ל-Soft Margin SVM מניח שאנחנו רוצים להביא למינימום את סכום החריגות מהשוליים, כלומר את  $\sum_{i=1}^n \xi_i$ . בשאלה זו, נרצה להביא למינימום את ריבועי החריגות מהשוליים. כלומר, נתונה הבעיה הבאה:

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{2} \sum_{n=1}^N \xi_n^2$$
$$\text{s.t. } y_n(\mathbf{w}^T \mathbf{x}_n + b) \geq 1 - \xi_n \quad \forall n = 1, \dots, N$$

כאשר  $\mathbf{x}_n \in \mathbb{R}^d$  ו-  $y_n \in \{+1, -1\}$ .

1. שימי לב שהשמטנו את האילוצים  $\xi_n \geq 0$  בבעיה זו. הראה/י שאפשר להוריד את אילוצי אי-השליליות הללו - כלומר, שהערך האופטימלי לא משתנה אם האילוצים מתווספים או לא.

תעודת זהות:  
מספר מחברת:

---

2. מהו הלגרנז'יאן בבעיה זו?



תעודת זהות:  
מספר מחברת:

---

3. מהי הבעיה הדואלית במקרה זה?

## שאלה 4 - 20 נקודות

1. נתון לנו מדגם מסווג  $(x_i, y_i)$ , כאשר  $x_i \in \mathbb{R}^d$  ו-  $y_i \in \{+1, -1\}$ . מריצים את אלגוריתם Perceptron על מדגם אימון במשך  $T$  איטרציות, עד לקבלת התוצאה הסופית  $w^*$ . הראה/י ש- $w^*$  הוא צירוף לינארי של נקודות המדגם  $x_i$ .

2. השתמש/י בתוצאות הסעיפים הקודמים כדי לשנות את Perceptron כך שישתמש ב-kernels. האלגוריתם לא ישמור במפורש את הערך של  $w^*$ , אלא ישמור ויעדכן בכל איטרציה את מקדמי הצירוף הלינארי שיוצר אותו. כתב/י פסאודו־קוד שמתאר את האלגוריתם החדש, והדגימ/י כיצד אפשר להשתמש בתוצאה שלו כדי לסווג נקודת מדגם חדשה  $x$ , מבלי לשמור במפורש את  $w^*$ .

## שאלה 5 - 20 נקודות

נתון לנו מדגם מסווג  $(\mathbf{x}_i, y_i)$ , כאשר  $\mathbf{x}_i \in \mathbb{R}^d$  ו-  $y_i \in \{+1, -1\}$ . נזכיר כי באיטרציה ה- $t$  של אלגוריתם AdaBoost, מעדכנים את ההתפלגות  $D_t$  על ידי:

$$\begin{aligned}h_t &= \arg \min_{h \in H} \Pr_{\mathbf{x} \sim D_t} [h(\mathbf{x}) \neq y] \\ \epsilon_t &= \Pr_{\mathbf{x} \sim D_t} [h_t(\mathbf{x}) \neq y] \\ \alpha_t &= \frac{1}{2} \ln \frac{1 - \epsilon_t}{\epsilon_t} \\ D_{t+1}(\mathbf{x}_i) &= \frac{D_t(\mathbf{x}_i) e^{-\alpha_t y_i h_t(\mathbf{x}_i)}}{Z_t}\end{aligned}$$

כאשר  $H$  היא מחלקה של השערות.

1. הראה/י כי

$$\epsilon_t e^{\alpha_t} = \sqrt{\epsilon_t(1 - \epsilon_t)} = (1 - \epsilon_t) e^{-\alpha_t}$$

2. הראה/י כי גורם הנורמליזציה  $Z_t$  הוא

$$Z_t = 2\sqrt{\epsilon_t(1 - \epsilon_t)}$$

תעודת זהות:  
מספר מחברת:

---

3. הרא/ה כי השגיאה של ההשערה הקודמת ביחס להתפלגות החדשה היא בדיוק חצי, כלומר:

$$\Pr_{\mathbf{x} \sim D_{t+1}} [h_t(\mathbf{x}) \neq y] = \frac{1}{2}$$

תעודת זהות:  
מספר מחברת:

---

4. האם בהכרח  $h_{t+1} \neq h_t$ ?