

תוכנית 1 – חורף 2022/23

תרגיל מס' 5

הנחיות כלליות:

קראו בעיון את קובץ נהלי הגשת התרגילים אשר נמצא באתר הקורס.

את התרגיל הבא צריך להגיש באופן הבא:

- הגשה במערכת-hGit תבצע על פי הנחיות שראיתם בתרגול 1.

צור את ה repository שלכם מתוך הקישור הבא:

<https://classroom.github.com/a/9MRhM2o>

יש לוודא שבתיקיית הגיט שלכם נמצאים הקבצים הבאים:

- a. קובץ פרטיים אישיים בשם details.txt המכיל את שם המשתמש שלכם ב Moodle ואת מספר תעודה זהה שלכם.

b. הקובץ java.java BigramModel.

- c. ניתן גם להשאיר את הקובץ java.java BigramModelTester.java ותיקית resources, אך לא חובה, כיוון שהם לא נבדקים (הוא נדרש לסייע לכם בבדיקה עצמית).

אין לצרף קבצים ותיקיות נוספות.

- הגשה במערכת Moodle (<http://moodle.tau.ac.il/>): עלייכם להגיש את קובץ הטקסט assignment.txt בו קישור לrepository git האישית שלכם.

בתרגיל זה נבנה מודל בסיסי של שפה (השפה האנגלית) מתוך טקסט נתון, תוך שימוש בסטטיסטיקה פשוטה של הופעת צמדים מיילים בטקסט. לדוגמה, אם הטקסט שלנו לומדים עליו הוא:
"here comes the sun"

הרי שבשפה שלנו יש 4 מילים, והצמדים <here, comes>, <comes, the>, <the, sun> מופיעים כל אחד פעמי אחת. הצמד <here, sun> לא מופיע בקובץ שלנו, ולכן סה"כ ראיינו אותו 0 פעמים. מודל השפה שלנו למעשה יכול את אוצר המילים ואת מספר המופיעים של כל צמד מיילים.

הערות חשובות למימוש

1. בתרגיל זה אתם יכולים להניח שככל שמות הקבצים הם חוקיים ואין צורך למש טיפול נפרד במקרה שקריאה או כתיבה לקובץ נכשלה. כמו כן, הניחו כי כל הקטל וכל מתודה הוא חוקי וכמצופה, אללא אם כן צוין אחרת בגוף הפונקציה ויש התיחסות מפורשת לטיפול בערכים שאינם חוקיים.

2. מותר לכתוב מתודות עזר, אך יש לשמר את כל באותו הקובץ, ולא ליצור עבורן מחלקות חדשות.

3. שימו לב גם להערה בסוף הנחיות התרגיל לגבי ה-Scanner. עדיף לישם אותה בשלב מוקדם.

4. שימו לב, בתוכנית זאת עלייכם להשתמש **במערכות בלבד**, ולא במבנה נתונים גנריים כמו Lists/Maps/Sets וכו'. **שימוש במבנה נתונים גנריים יכול לגרום להורדת ניקוד שימושית עד כדי ציון נכשל**. בפרט, אין להשתמש ב Arrays.asList() שכך שירות זה מייצר אוסף גנרי מטיפוס List.

בנייה מודל שפה

המחלקה `BigramModel` אשר נמצאת בחבילה `5.ex.cs.tau.ac.il` מייצגת את מודל השפה. מחלוקת זו מכילה שני שדות:

| משמעות | שדה |
|--|------------------------------------|
| מערך שמכיל את כל המילים באוצר המילים | <code>String[] mVocabulary</code> |
| מערך דו מימדי המכיל את מספר הפעמים שבו ניראה כל צמד מילים בקובץ ממנו למדנו את מודל השפה. האיבר במקומ ה j, n יהיה מספר הפעמים שראינו את המילה j מופיעה אחרי המילה n | <code>int[][] mBigramCounts</code> |

(1) [נקודות] משוו את המתודה `IndexVocabulary build` המקבלת שם קובץ מחזירה מערך מחזרות (`vocabulary`) אשר יהווה את אוצר המילים שלנו.

הערך vocabulary:

- יכול עד 14,500 מילים וחוקיות מוגן הקובץ. (השתמשו בקבוע שהוגדר עבור מספר המילים המקסימלי).
- מילה חוקית היא מילה העונה לפחות שתי ההגדרות:
 - i. מילה שמכילה לפחות אחת בשפה האנגלית.
 - ii. מספר שלם (למשל, 13 או 1984). מבחינת מקרי קצה, מספר שלם מוגדר בקונטקט שלנו כרצף ספרות ללא כל תו אחר. מותר שהמספר יתחל ב-0, אך אסור סימן פלוס או מינוס בהתחלה או נקופה עשרונית. אם יש תווים נוספים מלבד ספרות במילה, אז אם אחד מהם הוא אות אנגלית מדובר במילה מהסוג הראשון. אם יש תווים נוספים כך שאף אחד מהם אינו אות אנגלית, אז לא מדובר במילה חוקית.
- כל מילה חוקית שמכילה לפחות אחת באנגלית יש להמיר לlowercase.
- כל מספר שלם יומר למחזרות "num_some" (השתמשו בקבוע שהוגדר בתחלת המחלוקת). לפיך 55 ו-67 הם בעצםאות מילה: "num_something", ומופעים לערך יחיד במילון. לא צריך שתהיה חזרה של num_something במילון - כל המספרים הם בעצם אותה מילה וצריך להתייחס אליהם כפי שנחנו מתיחסים למילים שימושיות כמה פעמים. יש להתעלם מכל המילים הלא חוקיות.
- הכוונה בהמרה היא לא שינוי "פיזי" בקובץ הקלט, אלא שהתוכנית שלכם צריכה לrox על הקלט באופן זהה לחילוטין לריצתה על גירסה של הקולט בה כל המילים בו הוחלפו ל-lowercase וכל המספרים הוחלפו ב-"num_something". באופן דומה, מילים לא חוקיות לא נמחקות, אלא מועלמים מהן במהלך יצירת מילון המילים. אך אם בין שתי מילים חוקיות ישנה מילה לא חוקית, אז זה לא נכון להחשב את שתי המילים האלה כעוקבות, כיילו המילה הלא חוקית כלל לא קיימת.
- אם נצמד למילה מסוימת (שיש בה אותה א.ngליית לפחות לפחות) סימן כלשהו, כמו סימן פיסוק, אך לשם הפשטות, אנחנו נחשיב אותה כמילה נפרדת למילה ללא הסימן. כמו למשל המילה "man" ו-"man's" הין שתי מילים שונות. אותו דבר לגבי "java" ו-"java.". מותר, אך לא חובה, להיעזר בתבודה `Character.isDigit`. במחזרות ישן גם המתודות `charAt`, `toCharArray` והשימושים להן.

נכניס את המילים החוקיות לתוך המערך `vocabulary` (בגירסה המומרת של כל מילה, בהתאם להנחיות הקודמות) על פי סדר הופעתן בקובץ (המילה הראשונה תיכנס לאינדקס 0, וכן הלאה). במידה ומילה מופיעה פעמיים, היא תישמר רק פעם אחת, תחת האינדקס שבו נשמרת בפעם הראשונה שוראותה (למשל, אם המילה `the` היא המילה השלישית בקובץ ונכנסה ל `vocabulary` תחת האינדקס 2, בפעם הבאה שנירה אותה ה `vocabulary` לא ישנה).

במידה והקובץ מכיל יותר מ- K מילים **חווקיות שונות**, נשמר רק K מילים ב**vocabulary** (זה לא אומר שאנו שוארים מתעדמים במלטה הزادה משארית הקובץ אם הגענו לנקודה בה יש K מילים שונות, שכן הוא רלוונטי לשאלות אחרות). אם הקובץ מכיל פחות מ- K מילים שונות, גודלו של המערך **vocabulary** יותאם למספר המילים השונות בקובץ.

חתימת המתודה:

```
public String[] buildVocabularyIndex(String fileName) throws IOException
```

- (2) [15 נקודות] ממשו את המתודה **buildCountsArray** המקבלת שם קובץ (**filename**) ומערך **vocabulary**. המתודה תחזיר מערך דו מימדי של מספרים שלמים (**int**) אשר יוכל את מספר המופעים של צמדי מילים בקובץ **filename** על פי הפירוט הבא:
- אם $\text{word1} = \text{word2}$ **vocabulary[y]=word2**, אזי $[y][x]$ יכיל את מספר הפעמים שבהן המילה **word2** הופיע **מיד** אחר **word1**.
 - הנicho כי בקבוצי הקלט שלהם כל משפט יתחל בשורה חדשה. כמו כן, כל שורה חדשה שהיא לא ריקה מתחילה משפט חדש.
 - הסתטיסטיות תיאספונה רק עבור מילים שנמצאות באוצר המילים. אם הקובץ מכיל יותר מ- K מילים, צמדים שמכילים מילה שלא נמצאת ב**vocabulary** לא יספרו. שימו לב: זה לא אומר שלא ממשיכים לסרוק את הקובץ לאחר שהגענו ל- K אלף מילים שונות, אלא רק שמילים חדשות מעבר לנקודה הزادה כבר לא נחשבות חוותות (אך עדין סופרים זוגות של מילים חוותות עוקבות עד סוף הקובץ).
 - אם המילה **y** מעולם לא ניראה אחרי המילה **x**, אזי $[y][x]$ יכיל את הערך 0.
 - שים לב, בשאלת זו ובקדמתם אתם מתבקשים רק לבנות מערכיים מתאימים ולהחזיר אותם, אך לא לשים אותם בשדות **mBigramCount** ו-**mVocabulary**.

חתימת השירות:

```
public int[][] buildCountsArray(String fileName, String[] vocabulary) throws IOException
```

(3) [10 נקודות] החל מסעיף זה, ניתן להניח שלפני כל קריאה לאחד השירותים, הופעל השירות **loadModel**. שירות זה, שמיומו כבר נתון לכם, מקבל שם של קובץ ומיצר ממו מודל שפה ע"י קריאה לשני השירותים מסעיפים 1 + 2. אוצר המילים וטבלת הספירות ישמרו בשדות הסתטיטים **mBigramCounts** ו-**mVocabulary** שלו שהמודל מאותחל.

משו את המתודה **saveModel** המקבלת מחרוזת **fileName** ושומרת את המודל הנלמד (אוצר המילים וספירות הזוגות) לתוך שני קבצים. אוצר המילים ישמר לקובץ **voc.filename** ואילו הספירות ישמרו בקובץ **Vocabulary.counts** (העדרו בקובעים המוגדרים בחלוקת בשביל לקבל את שתי הסיומות).

בקובץ **voc**, ישמר אוצר המילים בפורמט הבא:

- השורה הראשונה תכיל את מספר המילים שנמצאות ב-**Vocabulary**.
- החל מהשורה השנייה תופיע כל מילה, יחד עם האינדקס שלה, בסדר עולה של האינדקסים.

במידה ויש מספרים בטקסט, אך **numSome** יופיע באינדקס של המספר הראשון שופיע בטקסט ולא יופיע שוב במילון.

דוגמא בעמוד הבא

עבור הקובץ `all_need_you.txt` אשר מכיל את הטקסט הבא:

```
Love love love  
All you need is love All you need is love love , Love is all you need  
נקבל קובץ voc. שנראה כך:
```

```
5 words  
0,love  
1,all  
2,you  
3,need  
4,is
```

בקובץ `counts`. הספירות של זוגות המילים ישמרו באופן הבא:

- בכל שורה נכתב את מספר המופיעים של כל זוג מילים, כאשר זוג המילים יוצג באמצעות האינדקסים שלהם באוצר המילים (vocabulary). את מספר המופיעים נכתב באותה השורה ונפרד בין שני האינדקסים באמצעות נקודות. • הצמד `<2,1>` כתוב לפני הцמד `<4,3>` אם `1` הוא נmor יותר מ `3`, או אם `1` ו `3` זהים, ו- `2` נmor יותר מ `4`.
- מכיוון שרוב צמדי המילים האפשריים לא ניראו בטקסט (מספר המופיעים הוא 0), נשמר בקוד את הצמדים שכנראו (כלומר, ערכיהם אינם 0).
- קובץ `counts`. עברו `all_need_you.txt` יראה כך.

```
0,0:3  
0,1:1  
0,4:1  
1,2:3  
2,3:3  
3,4:2  
4,0:2  
4,1:1
```

(סביר לפורת: השורה הראשונה מייצגת את הצמד `love, love` שנראתה 3 פעמים בקובץ) הטסטר מייצר את שני הקבצים האלה תחת השמות `voc` ו- `all_need_you.txt`. ניתן `filename.counts`. להניח כי שם הקובץ בפורט `filename` אינו מכיל סימנת.

חתימת המתודה:

```
public void saveModel(String fileName)
```

(**[10 נק']** השלימו את השימוש של המתודה `loadModel` מקבלת שם של קובץ (`fileName`) וטוענת משני הקבצים `voc` ו- `fileName.counts` מודל השפה לTOR השודת `mVocabulary` ו- `mBigramCounts`. במידה ושודת אלה מאותחלים לערכים אחרים, ערכים אלה דדרים (כלומר, אם המשתנים האלה כבר מצבעים למערכים כלשם, אז אנחנו מפינים אותם למערכים חדשים – דדרים את המערך עצמו – ולא דדרים תאים של מערך קיימים). הניתן כי שני קבצי המודל `voc` ו- `fileName.counts` קיימים. ניתן להניח כי שם הקובץ בפורט `filename` אינו מכיל סימנת. כמו כן, ניתן להניח שתוכן הקבצים הוא בפורט הנכון (שתואם לאופן שבו אנחנו יוצרים את הקבצים האלה), אם כי התוכן עצמו הוא לא בהכרח משווה שייצרנו בעצמנו במתודה אחרת בתוכנית.

חתימת המתודה:

```
public void loadModel(String fileName) throws IOException
```

(5) [נק'] ממשו את המתודה `getWordIndex` המקבלת מחרוזת ומחזירה את האינדקס שלה ב-Vocabulary. במידה ומחרוזת זו לא מופיעה, הפונק' תחזיר -1. (העוזר בקבוע שהוגדר בראש המחלקה). בשאלת זו (ובשאלות הבאות) ניתן להניח שכבר אין צורך לעשות המרות, כלומר מספרים או מילים עם אות באנגלית שאינה ב-lowercase כבר אין חוקיות, ואין צורך לבדוק את ההמרה שלהן.

חתימת המתודה:

```
public int getWordIndex(String word)
```

(6) [נקודות] ממשו את המתודה `getBigramCount` המקבלת שתי מחרוזות `word1` ו-`word2` ומחזירה את מספר הפעמים ש-`word2` הופיע אחרי `word1`. אם אין מילים לא קיימת באוצר המילים (פונק' `Vocabulary`) תחזיר 0.

חתימת המתודה:

```
public int getBigramCount(String word1, String word2)
```

(7) [נקודות] ממשו את המתודה `getMostFrequentProceeding` המקבלת מילה `word` ומחזירה את המילה שהופיע אחריה הכי הרבה פעמים. במידה ויש כמה מילים עם אותו מספר מופעים, תוחזר המילה בעלת האינדקס הנמוך יותר ב-`vocabulary`.
במידה ואחרי המילה `word` לא ניראה אף מילה אחרת (חשבו באיזה מצב זה יכול לקרות) המתודה תחזיר null.

חתימת המתודה:

```
public String getMostFrequentProceeding(String word)
```

(8) [נקודות] ממשו את המתודה `isLegalSentence` שמקבלת משפט `sentence` ובודקת אם מודל השפה שבנו ניתן של המשפט זה. מכיוון שמודל השפה מתאים ללמידה את מבנה השפה, ואת הקשרים בין המילים, המשפט יהיה חוקי אם כל זוג מילים צמודות שמוויות במשפט הופיע לפחות פעם אחת בטקסט עליי למדנו את מודל השפה (בעיני המרות, כמובן, מה שקובע זה המודל שבנו, ולא הגירסה ה"לא צומרת" של מילים בטקסט המקורי).

דוגמאות:

- המשפט `you all love all` הוא משפט "חוקי" במודל שנבנה על סמך הקובץ המתואר בסעיף 3. היצירוף `all love` נראה בקובץ התאמנו, וכן היצירוף `you all`. שימושו לבשלא ראיינו את כל המשפט בשלמותו בטקסט האימון, אבל זה לא משנה כי אנחנו מסתכלים רק על זוגות.
- המשפט `is love is` לא נראה בשום מקום בטקסט האימון.
- המשפט `the beatles love the beatles` גם כן אינו חוקי. המילים `the`, `beatles`, `love` כללו לא מופיעות בaczר המילים שלנו, ולכן ברור שלא ראיינו את היצירוף `the beatles love` וכן את היצירוף `the beatles` (שימוש לב, קלט זה הוא קלט חוקי לפונקציה).
- אם המשפט ריק או מכיל רק מילה אחת שנמצאית במילון יש להחזיר `true`.
- אם המשפט מכיל רק מילה אחת שאינה נמצאית במילון יש להחזיר `false`.

חתימת המתודה:

```
public boolean isLegalSentence(String sentence)
```

(9) [10 נקודות] נרצה לבדוק אם באמצעות מבנה הנתונים שלנו ניתן למודד משהו על התנהגות השפה והיחסים בין מילים. לצורך בדיקה זו, נשתמש בקובץ טקסט גדול, וננסה לראות אם יש קשר בין מילים שימושיות בקשר הטקסט בהקשר דומה: למשל, בשמות לאוטון המילים.

לצורך כך, משמש את המתודה הסטטistica `calcCosineSim` המקבלת שני מערכיים של מספרים שלמים שאורכם זהה, ומחשבת את דמיון הקוסינוסים ביניהם על פי הנוסחה הבאה:

$$\frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$$

כאשר A ו- B הם וקטורים באורך n המוממשים ע"י מערכיים של `int`-ים.
 A הוא האיבר ה- i במערך A , ו- B הוא האיבר ה- i במערך B .
כל שהוקטורים הם דומים יותר, הערך שנקלט יהיה גדול יותר.
לדוגמה: עבור שני וקטורים $[1,2,3]$, $[1,0,5]$ נבצע את החישוב הבא:

$$\frac{1 * 1 + 0 * 2 + 5 * 3}{\sqrt{1^2 + 0^2 + 5^2} * \sqrt{1^2 + 2^2 + 3^2}}$$

אם אחד הוקטורים מכיל רק אפסים, הפונקציה תחזיר -1.
אפשר להניח כי אורך המערכיים גדול מ-0.

חתימת המתודה הסטטיסטית:

```
public static double calcCosineSim(int[] arr1, int[] arr2)
```

- (10) [15 נקודות] כתה, נשתמש בפונקציה שמיימנו בסעיף הקודם כדי למצא את המילה הכי דומה למילה `word` כלשהי על פי הקשר שלהן בטקסט.
- נגיד את המושג "וקטור מייצג עבור מילה `word` כלשהי".
- עבור מילה `word` הקיימת באוצר המילים שלנו, הוקטור המייצג הוא וקטור הנוצר מトーר מודל השפה ואורכו הוא כמספר המילים באוצר המילים (`mVocabulary`).
 - האיבר במקומות ה- x יכול את מספר הפעמים שבו המילה `word` הופיע במאודן. נראה במודל השפה (כלומר, כמה פעמים ה策ורף `[x]` `word`, `mVocabulary[x]` `word` ומספר במודול).
 - לדוגמה: עבור מודל השפה שמתיואר בסעיף (2), המילה `love` תוצג באמצעות הוקטור הבא: $[3, 1, 0, 1]$.
 - סידור המילים באוצר המילים הוא: `is`, `need`, `you`, `all`, `love`, וכך האיבר הראשון בוקטור יציג את המופיע של `all` אחרי `love`, וכן הלאה.
 - ה策ורף `love` `love` מופיע שלוש פעמים על פי מודל השפה.
 - ה策ורפים `all` `love` מופיע פעמיים.
 - ה策ורפים `you` `love` ו- `need` אינם מופיעים כלל.
 - ה策ורף `is` `love` מופיע פעם אחת.
 - את הוקטורים המייצגים עבור כל מילה ניצג ע"י מערכיים חד ממדיים של מספרים שלמים שאורכם הוא כפול אוצר המילים.

- אם אוצר המילים הוא בגודל 1: כאשר אין מה להחזיר (כלומר יש תיקו בין כל המילים שלכלן יש אפס דמיון) מוחזרים את המילה עם האינדקס הכי נמוך, ככלומר הראשונה. במקרה זהה יש רק מילה אחת, אז נחזיר את המילה עצמה.

משמעות הפונקציה `getClosestWord` אשר מקבלת מילה `word` ומוחזירה את המילה הדומה לה ביותר על פי השוואת הוקטורים המיצגים של כל המילים לזרה של `word`.
עליכם לחוץ את הוקטור המיצג את `word` מתוך השדה `wordCounts`, ולאחר מכן, למצאו מילה שכך שהיא `cosineSim` בין הוקטור המיצג של `word` זה לבין זה של `word` הוא הגבוה ביותר מבין שאר המילים באוצר המילים. הציפייה שלנו היא שמלים בעליות וקטורים "דומים" יותר יהיו דומות במידה ומשמעות או באופן השימוש בהן בטקסט. במידה ויש שתי מילים להן דמיון זהה, יש להחזיר את זו שהאינדקס שלה קטן יותר.

חתימת המתודה:

```
public String getClosestWord(String word)
```

הערה לידע כללי:

על מנת לקבל תוצאות משמעותיות בשיטה המתוארת בסעיף 10 علينا להשתמש בכמות מאוד גדולה של טקסט, עם אוצר מילים רחב ודוגמאות שימוש רבות לכל מילה. כמו כן, علينا להשתמש במידע נוסף: לא להשוו רק את המילים שמופיעות אחרי המילה, אלא גם את המילים הקודמות לה, ולהשתמש ביותר ממילה עוקבת/קדמת אחת. יחד עם זאת, גם בשיטה המאוד בסיסית שמוגדרת בסעיף 10 ניתן להגעה לתוצאות מעניינות עבור הקובץ `emma.txt` (הספר "אמה" של ג'יין אוסטין, מתוך האתר <https://www.gutenberg.org>). כך למשל, נראה ש `good` ו- `great` הם בעלי וקטורים דומים יחסית, וכן `"she"`, `"he"` ועוד רבים אחרים.
מה שיכל לעזור לנו לשפר את התוצאות הוא עיבוד לשוני על הטקסט: למשל, להסביר את כל הטוויות הפעילים ושמות העצם לצורת היחיד (`book` → `books`, `go` → `goes`).
כאמור, השימוש שלכם הוא בסיסי ביותר, אבל מהו זה בסיס לטכניקות מתקדמות יותר בהן משתמשים בשביב ללמידה מייד על שפה. בפרט, בסעיף 8 אנחנו משתמשים במידה מוגבלת: ציפוי מילים שלא נראו בטקסט האימון גורמים לכך שהמשפט "איו חוקי". מdad זה נקבע רק לצורך התרגיל, וכמוון שאין לו משמעות בעולם האמתי של עיבוד שפה טבעית. במקרה, אנחנו נותנים למשפטים ציונים: כמה סבירים הם לאור המודל שנלמד.

שימוש בחוזים:

בשלד התרגיל מופיעים חוזים עבור חלק מהמתודות. השתמשו בחוזים על מנת להבין אילו הנחות אפשר להניח על הפלט, ובailio מקרי קצה צריך לטפל.

קריאה מקבצים:

במקרה של הפעלה, ה `Scanner` יכול לקרוא מהקבצים, שימו לב שעבור קבצים גדולים, בחלוקת ממערכות הפעלה, זה יכול להריץ (`java -jar filename.jar` הוא לא קריא כלום). זו בעיה מוכרת וידועה ב Java והמלצת היא לעבוד עם `BufferedReader` עבור קבצים גדולים.

טסטר:

לתרגיל זה מצורפת מחלוקת טסטר. על מנת להריץ את הטסטר עליהם לודא שהנתיבים לקבצים מהם קוראים/כותבים תואמים למיקומם על המחשב שלכם, **ולעדכן את כתובות הקבצים במידת הצורך**.
מומלץ להוציא בדיקות משלכם תוך שימוש בקבצי טקסט חדשים. ברוב המקרים כדאי להשתמש בקבצי קלט קצרים עליהם קל ליחס את התשובה אותה תרצה לקבל מהפונקציות שלכם.

בהצלחה!