מרכז המורים הארצי למקצועות הטכנולוגיים
הפקולטה לחינוך למדע וטכנולוגיה, הטכניון, מכון טכנולוגי לישראל, חיפה 320003
טל: 73-3783146 972+ E-mail: Moretech@ed.technion.ac.il
https://moretech.technion.ac.il

למידת מכונה עמוקה (חלק א)

משימות ותרגילים

מחבר

ידידיה כהן

ייעוץ מדעי ופדגוגי:

גדי הרמן

אריאל בר יצחק

מפמ"ר מגמת הנדסת אלקטרוניקה ומחשבים:

שלומי אחנין

תשפ"ד

הספר מבוסס על השתלמות למורים של אריאל בר יצחק וכולל צילומי מסך מתוך מצגות וחומרי לימוד של ד"ר קובי מייק ואריאל בר יצחק.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

מרכז המורים הארצי למקצועות הטכנולוגיים
הפקולטה לחינוך למדע וטכנולוגיה, הטכניון, מכון טכנולוגי לישראל, חיפה 320003
טל: 73-3783146 972+ E-mail: Moretech@ed.technion.ac.il
https://moretech.technion.ac.il

© כל הזכויות שמורות למשרד החינוך

מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק

הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020

הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

האוגדן יצא לאור במימון האגף למדעים במזכירות הפדגוגית ומינהלת מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי.

אין לשכפל, להעתיק, לצלם, להקליט, לתרגם, לאחסן במאגר מידע, לשדר או לקלוט בכל דרך או אמצעי אלקטרוני, אופטי או מכני או אחר כל חלק שהוא מהחומר שבחוברת זו. שימוש מסחרי מכל סוג שהוא בחומר הכלול בחוברת זו אסור בהחלט אלא ברשות מפורשת בכתב מהמו"ל.

מרכז המורים הארצי למקצועות הטכנולוגיים
הפקולטה לחינוך למדע וטכנולוגיה, הטכניון, מכון טכנולוגי לישראל, חיפה 320003
E-mail: Moretech@ed.technion.ac.il +972 73-3783146 :טל
https://moretech.technion.ac.il

תוכן עניינים

מבוא וסביבת עבודה 1
מבוא ללמידת מכונה 1
טעינה ותצוגה של נתונים באתר Colab 2
רגרסיה לינארית 10
מבוא ודוגמאות 10
חיזוי באמצעות רגרסיה ליניארית תוך שימוש ב- scikit-learn 14
חיזוי הכולל מאפיינים מרובים 18
תרגיל השלמת קוד Linear regression 19
פונקציית המחיר ו-gradient descent 20
רגרסיה ליניארית חד/רב ממדית 23
רגרסיה לוגיסטית 24
הערכת ביצועים של מסווג 24
מדידת ביצועים של מסווג – תרגיל 26
רגרסיה לוגיסטית – הגדרה 26
סיווג על ידי רגרסיה לוגיסטית – תרגיל 29
תהליך האימון ברגרסיה לוגיסטית 30
רגרסיה לוגיסטית ב-sklearn 31
רגרסיה לוגיסטית ב-sklearn – תרגיל 33
למידה עמוקה - רשת נוירונים 36
טעינת dataset לגוגל Colab 36
למידה עמוקה 37
נוירון 38
Sklearn MLPClassifier 42
MLP Classifier – תרגיל 46
הפרדת ה-Dataset ל-Train ו-Test 52
חלוקה ל-Train, Test – תרגיל 54

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

מבוא וסביבת עבודה

מבוא ללמידת מכונה

מדעי הנתונים – מדע בין-תחומי עם שילוב של תחום מדעי המחשב, תחום המתמטיקה/סטטיסטיקה + התחום המדעי של התוכן של המידע. ולכן, פרויקטים מתבצעים כאן בדרך כלל מתבצעים ע"י שיתוף פעולה בין מומחים מהתחומים השונים.

הפרדיגמה החדשה של למידת מכונה – מזינים למכונה דוגמאות של נתוני כניסה ופתרונות והמכונה קובעת את חוקי הקשר (אלגוריתם) בין נתונים לפתרונות ולאחר מכן מפעילה את החוקים הללו על נתוני כניסה של בעיות "אמיתיות" ומחשבת את הפתרונות. וזאת, לעומת הגישה הקלאסית בתכנות – מזינים למכונה נתוני כניסה וחוקי הקשר (אלגוריתם) בין נתונים לפתרונות והמכונה מחשבת את הפתרונות.

Artificial Intelligence – (בינה מלאכותית) – ללמד מכונה לחשוב כמו בני אדם. בתוך התחום של הבינה המלאכותית יש את התחום של Machine Learning (לימוד מכונה) – המכונה פותרת בעיות באמצעות דוגמאות ללא חוקי קשר. בתוך התחום של לימוד מכונה יש את התחום של Deep Learning (למידה עמוקה) - למידה באמצעות מנגנון artificial neural networks (רשתות עצביות).

בתוך ה-Machine Learning קיימים 3 תחומים עיקריים:

- Supervised learning – דוגמאות עם תיוגים כפי שדיברנו קודם.
- Un-Supervised learning – למשל, ניתן למחשב הרבה דוגמאות של אותיות האלף-בית (בלי לתייגן) והמחשב ידע לחלקן לקבוצות של האותיות השונות על בסיס הקירבה בין התמונות השונות של אותה אות.
- Reinforcement learning – למידה מתוך התנסות ללא השלב של האימון המוקדם שב-Supervised. רלוונטי, למשל, לתחום של משחקים בו המכונה לומדת מניצחונות/הפסדים ומשתפרת עם הניסיונות.

רוב השוק נמצא ב-Supervised ולכן אנו נתמקד בתחום הזה.

סוגי בעיות:

- זיהוי (Classification)
  - Binary Classification – זיהוי מצב (מחלקה) מתוך 2 מצבים (מחלקות) אפשריים. למשל, קבלת mail והחלטה הם זה spam או לא. ניתן לפתור בעיות אלה בשיטות של Multiclass Classification אבל בגלל שלסוג הבעיות הללו יש פתרון יעיל יותר ואלו בעיות נפוצות, הגדירו לנושא תחום נפרד.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

- ○ Multiclass Classification – זיהוי מחלקה מתוך יותר מ-2 מחלקות אפשריות. למשל, זיהוי תמונת חתול מתוך אוסף האפשרויות של תמונת כלב, חתול, סוס, דג וציפור. הפתרון ייתן אחוזי הסתברות של כל אחת מהאפשריות עם סכום הסתברות כוללת של 100% והאפשרות עם ההסתברות הגבוהה ביותר היא המומלצת.
- ○ Multi-Lable Classification – זיהוי יותר ממחלקה אחת מתוך יותר מ-2 מחלקות אפשריות. למשל, זיהוי תמונת חתול וציפור מתוך אוסף האפשרויות של תמונת כלב, חתול, סוס, דג וציפור. הפתרון ייתן אחוזי הסתברות של כל אחת מה- lables וסכום ההסתברויות יהיה גדול מ-100%.

- **זיהוי ומיקום** (Classification + Localization) - תיחום האובייקט המזוהה באמצעות מלבן.
- **גילוי** (Object Detection) זיהוי ותיחום מלבני של מספר אובייקטים (מאותו סוג ומסוגים שונים) באותה תמונה.
- Instance Segmentation - גילוי ברמה של פיקסלים. כמו ב-Object Detection אבל התחום הוא עם מעטפת של קו המקיף את גבולות התמונה של האובייקט.

טעינה ותצוגה של נתונים באתר Colab

אתר Google Colab Notebooks הוא סביבת פיתוח בפייתון בענן של Google. האתר משתמש במשאבים (כוח חישוב, זיכרון, ספריות,...) של google וביצוע restart מתבצע למעשה על ה-session שלנו באתר ולא על המחשב שלנו. כל העבודות שנבצע באתר הזה מתבצעות כ"מחברת אינטראקטיבית" נשמרות באתר וזמניות להמשך פיתוח בכניסות הבאות.

קישור לאתר Google Colab. ניתן להגיע לאתר גם על ידי חיפוש בגוגל: "גוגל קולאב" וכניסה ללינק הראשון.

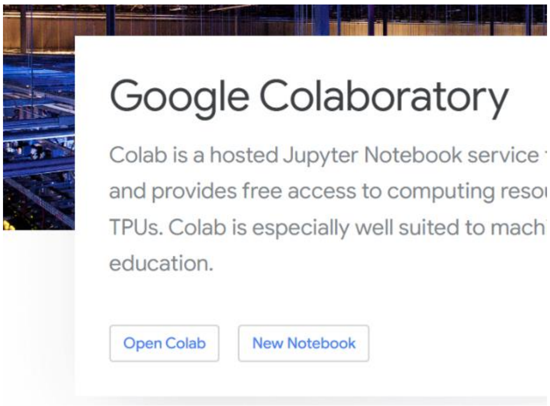

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

היות וזו המחברת הראשונה שלכם, יש לבחור ב-New Notebook ומקבלים את המסך:

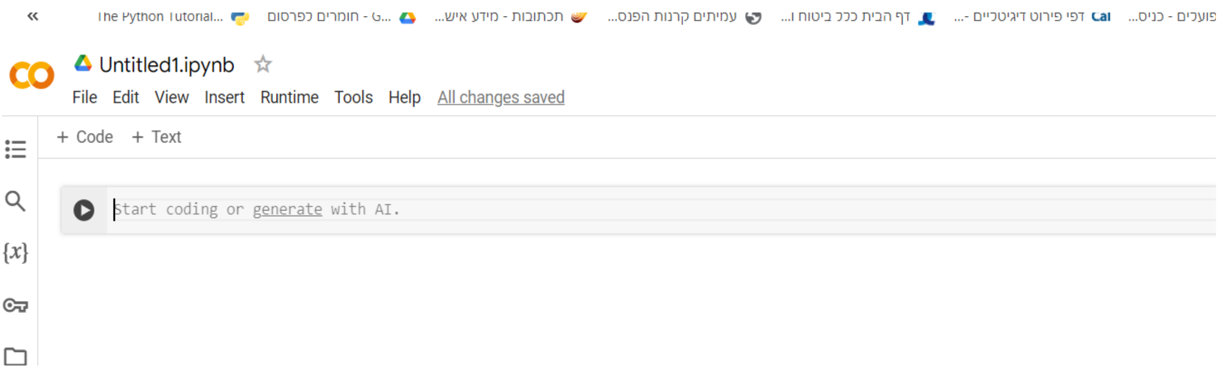

יתרונות של פיתוח פייתון ב-Colab (לעומת Visual Studio, למשל):

- אין צורך לטעון ספריות.
- הכל נשמר באופן מסודר בענן.
- ניתן להריץ קטעים של התוכנה.
- ניתן לשלב במחברת קטעי טקסט, תמונות, טבלאות.
- שימוש חינמי במשאבים (כולל GPU) של גוגל.
- כל מה שנדרש מהמחשב עליו עובדים הוא דפדפן.

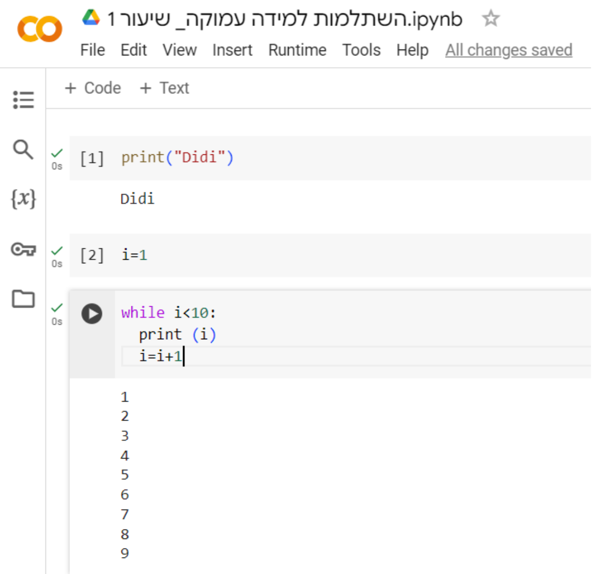

את המשך התיעוד המפורט של פרק זה רושמים במחברת הראשונה שנפתחה ושומרים אותה בשם/קישור "[למידה עמוקה שיעור 1]". במחברת מתועדים הנושאים הבאים:

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

כתיבת קוד (פייתון) והרצתו

כתיבת הקוד מתבצעת כתא (cell) המורץ בנפרד באמצעות ומקבל מספר שוטף של ההרצה (המספר שבסוגריים [ ]). המחשב זוכר את ערכי המשתנים ולכן הרצה נוספת של הבלוק הארון לא תדפיס כלום כי הערך הנוכחי של i הוא 10.

אפשר להריץ:

- תא בודד - באמצעות או Runtime/Run the focused cell
- את כל התאים – באמצעות Runtime/Run All
- את כל התאים שלפני התא הנבחר – באמצעות Runtime/Run before
- את כל התאים החל מהתא הנבחר – באמצעות Runtime/Run after
- את כל התאים הנבחרים (באמצעות Cntl ולחצן שמאל של העכבר) - באמצעות Runtime/Run selection

המחברות נשמרות ב-google drive האישי. ניתן להגיע ל-drive האישי באמצעות בסרגל הכלים ובחירת Drive.

על מנת לאתר בקלות במסך שיפתח 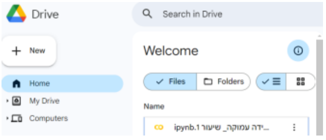

את כל המחברות שפתחתם ב-Colab, יש לבחור Folders ואז מקבלים 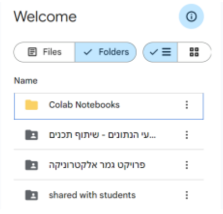

ומוציאים שם את 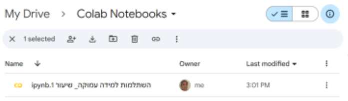

שילוב טקסט ותמונות

שילוב שורות טקסט ותמונות בין תאי הקוד.

שילוב שורת טקסט ככותרת למספר תאים ושורות טקסט באמצעות בסרגל שורות הכותרת נכנסות לתוכן העניינים המוצג בחלון משמאל ומאפשרות הסתרה וגילוי של קטעים במחברת לנוחות ויעילות העבודה.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

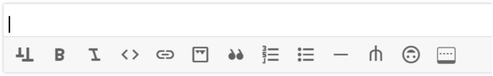

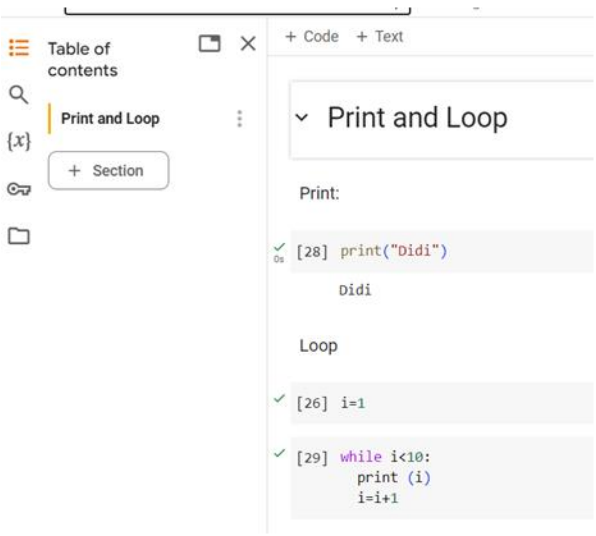

שילוב תמונות באמצעות . אם מקבלים כתובת קישור במקום התמונה, יש ללחוץ על Shift Enter או ללחוץ בכל מקום מחוץ לתא.

טיפול בטבלאות והצגת גרפים

על מנת לעבוד בפייתון יש לבצע יבוא של ספריות (כל הספריות הנדרשות מותקנות ב-Colab). מתחילים עם הספריות הנדרשות על מנת לטפל בטבלאות ונציג גרפים:

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
```

- ספריית numpy פועלת על מערכים
- ספריית pandas פועלת על טבלאות נתונים
- ספריית matplotlib היא ספריית גרפית (בסיס)
- ספריית seaborn היא ספריה גרפית (הרחבה לסטטיסטיקה)

כל הקיצורים כאן הם השמות המקובלים בכל העולם ויש להשתמש בהם ולא בשמות אחרים.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

לתרגול פתחו את הקישור הבא:

https://colab.research.google.com/drive/1_s1uH0BseMDTbBGvJ6lgkJkJ1aMt5dok?usp=share_link

לאחר פתיחת המחברת מקבלים קטעי קוד המדגימים יבוא נתונים המייצגים מידע על כותרת בפרחי IRIS:

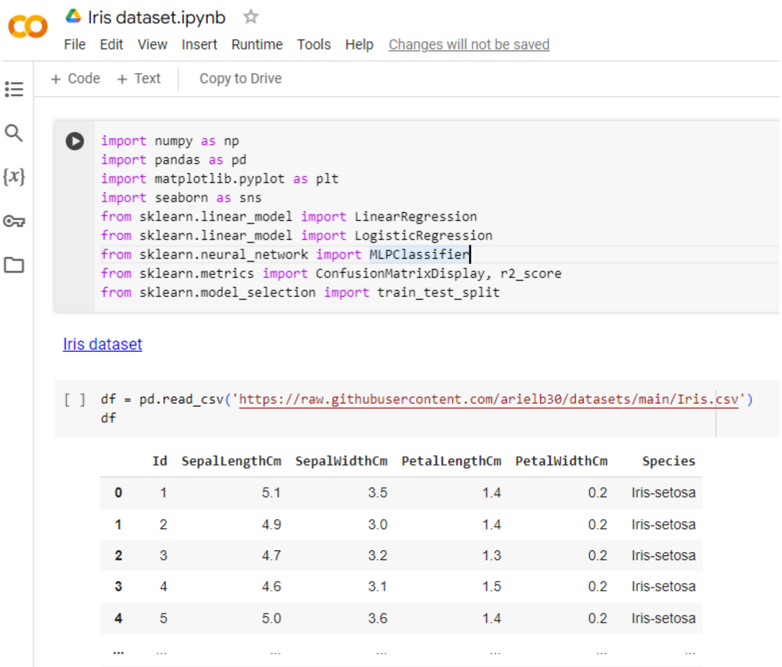

בקצה הימני של שורת התפריט רשום Changes will not be saved וזאת משום שזו המחברת של משתמש אחר. ולכן יש לשמור אותה באמצעות Copy To drive. השמירה יוצרת מחברת חדשה בשם Copy of Iris dataset עם הקישור הזה. ניתן לשנות את השם (אני שיניתי מ-Copy of Iris dataset ל-Iris dataset) ואז מקבלים:

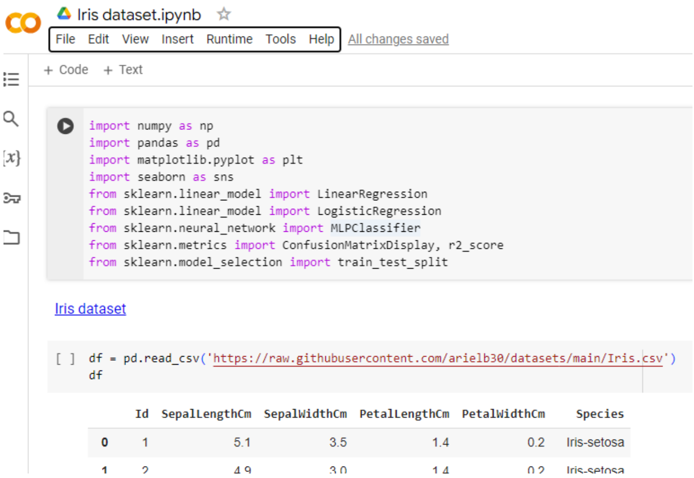

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

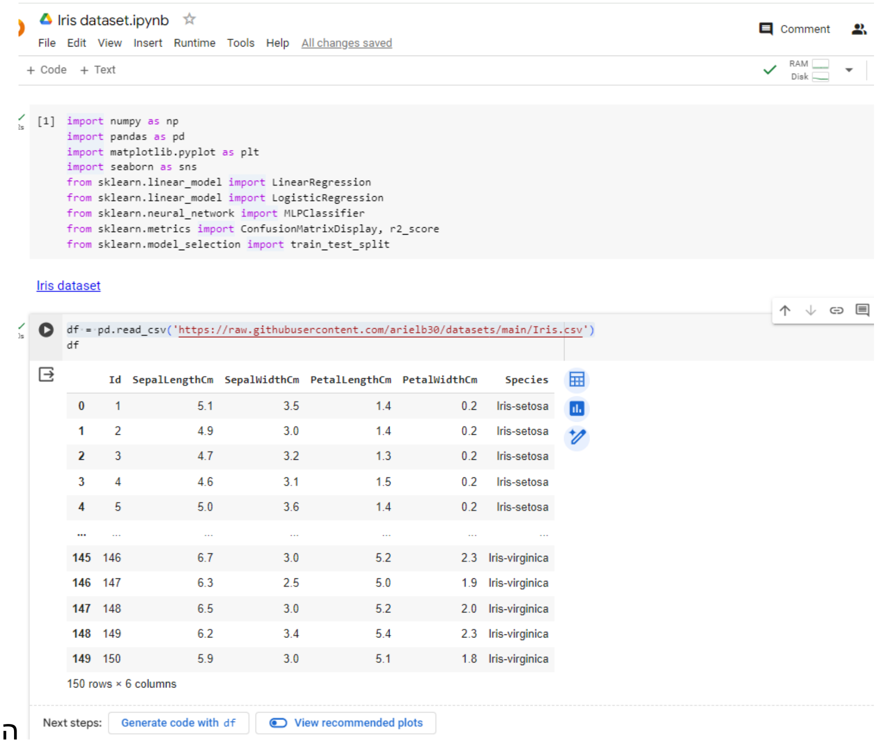


```
[1] import numpy as np
    import pandas as pd
    import matplotlib.pyplot as plt
    import seaborn as sns
    from sklearn.linear_model import LinearRegression
    from sklearn.linear_model import LogisticRegression
    from sklearn.neural_network import MLPClassifier
    from sklearn.metrics import ConfusionMatrixDisplay, r2_score
    from sklearn.model_selection import train_test_split
```

Iris dataset

```
df = pd.read_csv('https://raw.githubusercontent.com/arielb30/datasets/main/Iris.csv')
df
```

	Id	SepalLengthCm	SepalWidthCm	PetalLengthCm	PetalWidthCm	Species
0	1	5.1	3.5	1.4	0.2	Iris-setosa
1	2	4.9	3.0	1.4	0.2	Iris-setosa
2	3	4.7	3.2	1.3	0.2	Iris-setosa
3	4	4.6	3.1	1.5	0.2	Iris-setosa
4	5	5.0	3.6	1.4	0.2	Iris-setosa
...	...	...	...	...	...	...
145	146	6.7	3.0	5.2	2.3	Iris-virginica
146	147	6.3	2.5	5.0	1.9	Iris-virginica
147	148	6.5	3.0	5.2	2.0	Iris-virginica
148	149	6.2	3.4	5.4	2.3	Iris-virginica
149	150	5.9	3.0	5.1	1.8	Iris-virginica

150 rows × 6 columns

Next steps: Generate code with df | View recommended plots

הפלטים המוצגים במחברת הם תוצאת הריצה האחרונה אצל המשתמש האחר. על מנת להריץ את המחברת שלי, יש לבצע Runtime/Run all ואז מקבלים:

השינוי באזור הימני של סרגל הכלים מ- 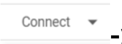 ל- אומר שהדפדפן התחבר לשרת ה-Colab והשתמש במשאביו על מנת לבצע את הריצה.

השורה Iris dataset היא שורת טקסט של קישור לאתר caggle, הידוע לכל קהילת ה-Data Sience, בו נמצא בסיס הנתונים המקורי של פרח ה-IRIS (ועוד הרבה בסיסי נתונים אחרים).

ההוראה:

```
df = pd.read_csv('https://raw.githubusercontent.com/arielb30/datasets/main/Iris.csv')
```

עושה השמה לעצם בשם df (קיצור של Data Frame) שהוא למעשה טבלה (Frame=).

pd.read_csv – מספריית pandas (pd) היא פעולת קריאה מקובץ CVS (קובץ בו כל שורה היא רשומה עם ערכים מופרדים בפסיקים). בתוך הסוגריים נמצא הקישור לקובץ ב-github של בעלי הקובץ.

משרד החינוך המזכירות הפדגוגית אגף א' למדעים | מנהל החינוך הטכנולוגי | מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט | מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים | הטכניון מכון טכנולוגי לישראל | הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

ההוראה df בשורה שלאחר מכן מציגה את הטבלה.

פקודה נוספת של הצגת נתוני הטבלה כגרף פיזור של שני משתנים :

```
[4] sns.scatterplot(data=df, x='SepalLengthCm', y='PetalLengthCm', hue='Species');
```

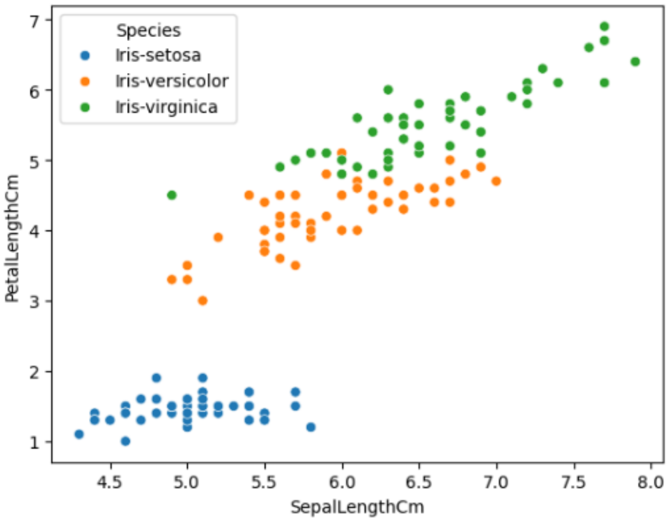

המקרא והצבעים נוצרים אוטומטית לפי hue='Species'.

```
df.columns

Index(['Id', 'SepalLengthCm', 'SepalWidthCm', 'PetalLengthCm', 'PetalWidthCm',
       'Species'],
      dtype='object')
```

ההוראה df.columns מאפשרת העתקה קלה של שמות העמודות בטבלה.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

על מנת לספור את כמות הפרחים מכל סוג בטבלה:

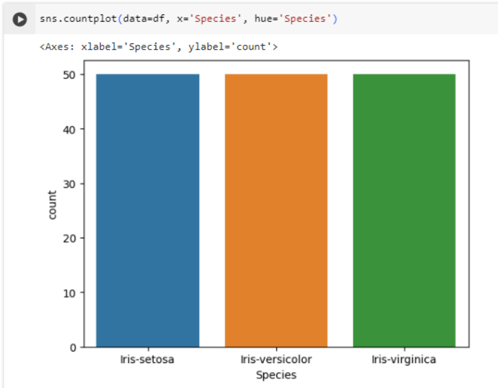

ניתן לשנות את מפת הצבעים באמצעות בחירת ה-palette :

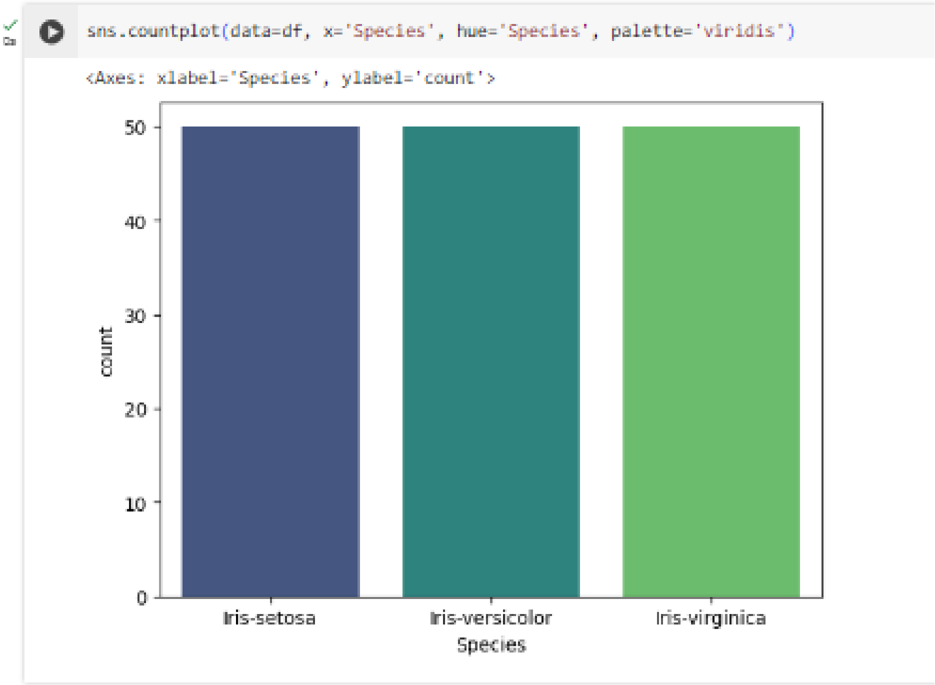

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

מרכז המורים הארצי למקצועות הטכנולוגיים
הפקולטה לחינוך למדע וטכנולוגיה, הטכניון, מכון טכנולוגי לישראל, חיפה 320003
טל: 3783146-73 972+ E-mail: Moretech@ed.technion.ac.il
https://moretech.technion.ac.il

רגרסיה לינארית

מבוא ודוגמאות

מתחילים בהדגמה בתחום למידת מכונה הנקרא רגרסיה לינארית, כי התהליך פשוט יחסית להבנה ולהוראה.

רגרסיה – חיזוי משתנה רציף בעל מספר אינסופי של ערכים. למשל, משקל, אורך, מחיר וכו'. וזאת לעומת משתנה בדיד בעל מספר סופי של ערכים כמו מספר ילדים במשפחה, יום בשבוע, ערים במדינה וכו'.

להלן הדגמת התהליך של חיזוי מחיר (=מטרה) של בית לפי המאפיינים שלו שמשפיעים על המחיר:

חיזוי באמצעות רגרסיה לינארית עשוי להתאים בהם הקשר בין המטרה והמאפיינים הוא קשר בעל אופי לינארי.

המשוואה החד ממדית $\hat{y} = w * x + b$ מתארת את נוסחת החישוב של חיזוי (Predict) משתנה מטרה בודד $\hat{y}$ (̂ מסמן גודל מוערך) לפי מאפיין בודד x לאחר תהליך אימון (אותו נתאר בהמשך) בו חושבו המקדם w (משקל, weight) והקבוע b האופטימליים. המשוואה $\hat{y} = w * x + b$ ניתנת כמובן לתיאור במערכת הצירים x,$\hat{y}$ כקו ישר בעל שיפוע w החותך את ציר ה-$\hat{y}$ בנקודה b.

את המשוואה החד ממדית ניתן להרחיב למשוואה רב ממדית $\hat{y} = w_1 * x_1 + w_2 * x_2 + \cdots + w_n * x_n + b$

בדוגמא שלהלן רואים שיש קשר בעל אופי לינארי עולה בין אורך העלה ורוחבו. הקורלציה היא מדד המתאר את מידת הלינאריות של הקשר הלינארי והיא יכולה לנוע בין 1 במצב של לינאריות עולה מושלמת (כל הנקודות מונחות על אותו ישר עולה) לבין 1- במצב של לינאריות יורדת מושלמת (כל הנקודות מונחות על אותו ישר יורד). הערכים בין 1 ל-1- הם

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
MoreTech מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

קורלציה חלקית בהן הנקודות מפוזרות סביב הישר המחושב. קורלציה 0 משמעותה חוסר קשר לינארי מוחלט (למשל, נקודות המונחות על מלבן).

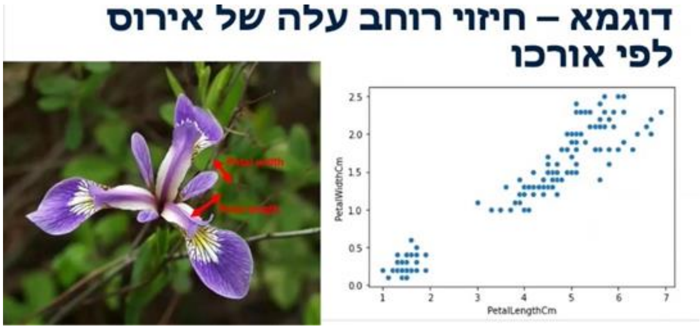

ניתן לשער מהדוגמא לחיזוי רוח עלה של האירוס שבאיור, שהקורלציה היא בערך 0.7-0.8. וזה אומר שניתן לייצר תחזית של רוחב העלה בהינתן אורך העלה.

כאשר יש מספר משתנים, כמו בדוגמת מחירי הבתים ורוצים לבצע חיזוי לינארי, צריך שלפחות לחלק מהמשתנים שיהיה קשר בעל אופי לינארי עם המשתנה אותו רוצים לחזות.

הדגמת חישוב קורלציה

פתחו את המחברת של ב-Iris dataset שמרו אותה בכונן שלכם Save Copy In drive (כי רוצים לבצע בה שינויים). השמירה יוצרת מחברת חדשה בשם Copy of Iris dataset עם הקישור הזה. ניתן לשנות את השם (ניתן לשנות מ-Copy of Iris dataset ל-Iris dataset).

הפעילו פעולת ()df.corr המחשבת ומציגה את הקורלציה בין המשתנים שבטבלה df. את הפעולה corr. יש להפעיל רק על עמודות עם ערכים מספריים ולכן יש לסלק את עמודת ה-**Species** וגם את עמודת ה-Id שלא מעניינת אותכם לצרוך קורלציה:

```
df.drop(['Species','Id'] ,axis=1)
```

	SepalLengthCm	SepalWidthCm	PetalLengthCm	PetalWidthCm
0	5.1	3.5	1.4	0.2
1	4.9	3.0	1.4	0.2
2	4.7	3.2	1.3	0.2
3	4.6	3.1	1.5	0.2
4	5.0	3.6	1.4	0.2
...	...	...	...	...
145	6.7	3.0	5.2	2.3
146	6.3	2.5	5.0	1.9
147	6.5	3.0	5.2	2.0
148	6.2	3.4	5.4	2.3
149	5.9	3.0	5.1	1.8

150 rows × 4 columns

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

axis=1 מכוון לעמודה, axis=0 מכוון לשורה. פעולת המחיקה הזו היא למעשה מחיקה זמנית לצורך תצוגה בלבד ואם מציגים שוב את df מקבלים:

```
[7] df
```

	Id	SepalLengthCm	SepalWidthCm	PetalLengthCm	PetalWidthCm	Species
0	1	5.1	3.5	1.4	0.2	Iris-setosa
1	2	4.9	3.0	1.4	0.2	Iris-setosa
2	3	4.7	3.2	1.3	0.2	Iris-setosa
3	4	4.6	3.1	1.5	0.2	Iris-setosa
4	5	5.0	3.6	1.4	0.2	Iris-setosa
...	...	...	...	...	...	...
145	146	6.7	3.0	5.2	2.3	Iris-virginica
146	147	6.3	2.5	5.0	1.9	Iris-virginica
147	148	6.5	3.0	5.2	2.0	Iris-virginica
148	149	6.2	3.4	5.4	2.3	Iris-virginica
149	150	5.9	3.0	5.1	1.8	Iris-virginica

150 rows × 6 columns

אם רוצים למחוק לגמרי, יש להוסיף לפקודה Inplace=True. מחקו לגמרי והפעילו את df.corr() מקבלים את מטריצת הקורלציה בין 4 המשתנים שבטבלה:

```
[11] df.corr()
```

	SepalLengthCm	SepalWidthCm	PetalLengthCm	PetalWidthCm
SepalLengthCm	1.000000	-0.109369	0.871754	0.817954
SepalWidthCm	-0.109369	1.000000	-0.420516	-0.356544
PetalLengthCm	0.871754	-0.420516	1.000000	0.962757
PetalWidthCm	0.817954	-0.356544	0.962757	1.000000

אלכסון המטריצה מתאר את הקורלציה של כל אחד מ-4 המשתנים עם עצמו וכולם כמובן 1. ניתן לראות שהקורלציה בין **SepalLengthCm** ובין **SepalWidthCm** היא לא טובה (-0.109369). ואכן, אם מציגים את גרף הפיזור שלהם מקבלים פיזור עם ליניאריות נמוכה (הנקודות רחוקות מישר כלשהו) ומגמה שלילית (גבוה עבור SepalWidthCm ערכי SepalLengthCm נמוכים ולהיפך):

```
sns.scatterplot(data=df,x='SepalLengthCm', y='SepalWidthCm')
<Axes: xlabel='SepalLengthCm', ylabel='SepalWidthCm'>
```

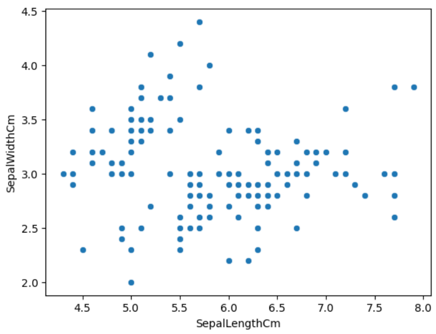

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

לעומת זאת ניתן לראות שהקורלציה בין **SepalLengthCm** ובין **PetalLengthCm** היא טובה (0.871754). ואכן, אם מציגים את גרף הפיזור שלהם מקבלים פיזור עם לינאריות די טובה (הנקודות די קרובות לישר העובר בתוך הפיזור) ומגמה חיובית (PetalLengthCm גבוה עבור ערכי SepalLengthCm גבוהים ולהיפך):

```
sns.scatterplot(data=df,x='SepalLengthCm', y='PetalLengthCm')
```

```
<Axes: xlabel='SepalLengthCm', ylabel='PetalLengthCm'>
```

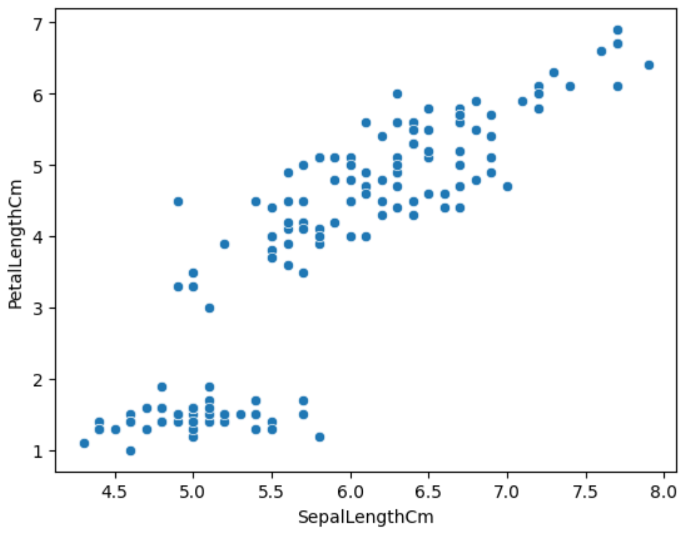

מטבלת הקורלציה ניתן ללמוד אילו משתנים קל יותר לחזות (למשל, **PetalLengthCm**) ואילו קשה יותר (למשל, **SepalWidthCm**).

אפשר לבצע חישוב קורלציה גם עם "מחיקה זמנית" של העמודות הלא רלוונטיות באמצעות הצמדת פעולת ה- corr. בשורת המחיקה הזמנית:

```
df.drop(['Species','Id'] ,axis=1, inplace=False).corr()
```

	SepalLengthCm	SepalWidthCm	PetalLengthCm	PetalWidthCm
SepalLengthCm	1.000000	-0.109369	0.871754	0.817954
SepalWidthCm	-0.109369	1.000000	-0.420516	-0.356544
PetalLengthCm	0.871754	-0.420516	1.000000	0.962757
PetalWidthCm	0.817954	-0.356544	0.962757	1.000000

משרד החינוך
המזכירות הפדגוגית
אגף א' למדעים
מנהל החינוך הטכנולוגי
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

חיזוי באמצעות רגרסיה ליניארית תוך שימוש ב- scikit-learn

scikit-learn היא ספרייה פופולרית של בשפת Python למימוש יישומים ב**למידת מכונה** הודות למחלקות רבות המשמשות לסיווג ורגרסיה והודות לקלות השימוש בהן.

יש לייבא את מחלקת LinearRegression מהספריה sklearn.linear_model:

```
from sklearn.linear_model import LinearRegression
```

מבצעים עכשיו משימה של חיזוי משתנה אחד (PetalWidthCm) מתוך משתנה אחד (PetalLengthCm):

הגדרת המשתנה ממנו אנו רוצים לחזות:

```
X=df[['PetalLengthCm']].to_numpy()
```

שם המשתנה (X) הוא אות גדולה היות ועבור המקרה הכללי של חיזוי ממספר משתנים זו תהיה מטריצה שמייצגת את טבלת המשתנים מהם רוצים לחזות ומטריצה נהוג לסמן באות גדולה. גם הסוגריים הכפולים ([[) הם הכנה למקרה הכללי של חיזוי ממספר משתנים.

הגדרת המשתנה אותו אנו רוצים לחזות:

```
y=df['PetalWidthCm'].to_numpy()
```

שם המשתנה (y) הוא אות קטנה היות וגם עבור המקרה הכללי של חיזוי במספר דוגמאות של פרחים זה יהיה וקטור (ובמקרה הפרטי שלנו רק מספר בודד) וקטור (או מספר) נהוג לסמן באות קטנה. כאן אין צורך להכין סוגריים כפולים היות והחיזוי במחלקת LinearRegression מתבצע תמיד על משתנה בודד.

```
X=df['PetalLengthCm']
X

0      1.4
1      1.4
2      1.3
3      1.5
4      1.4
      ...
145    5.2
146    5.0
147    5.2
148    5.4
149    5.1
Name: PetalLengthCm, Length: 150, dtype: float64
```

הפעולה ()to_numpy :

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

הצגת עמודה בפורמט של סוגר בודד scikit-learn שנקרא Pandas Series שהוא למעשה ווקטור בו ניתן להציג עמודה אחת בלבד (ללא הכותרת של שם העמודה)

```
[17] X=df[['PetalLengthCm']]
     X
```

	PetalLengthCm
0	1.4
1	1.4
2	1.3
3	1.5
4	1.4
...	...
145	5.2
146	5.0
147	5.2
148	5.4
149	5.1

150 rows × 1 columns

לעומת הצגה בפורמט של סוגריים כפולים שנקרא Pandas DataFrame וניתן להכניס בו יותר מעמודה אחת (עם הכותרת של שם העמודה) וזו למעשה מטריצה.

```
X=df[['PetalLengthCm','SepalLengthCm']]
X
```

	PetalLengthCm	SepalLengthCm
0	1.4	5.1
1	1.4	4.9
2	1.3	4.7
3	1.5	4.6
4	1.4	5.0
...	...	...
145	5.2	6.7
146	5.0	6.3
147	5.2	6.5
148	5.4	6.2
149	5.1	5.9

150 rows × 2 columns

ה-numpy יודע לעבוד על מערכים (ולא על ווקטורים/מטריצות) ולכן יש צורך להסב את X ו-y למערכים באמצעות הפעולה ()to_numpy.

```
[27] X=df[['PetalLengthCm']].to_numpy()
     X

array([[1.4],
       [1.4],
       [1.3],
       [1.5],
       [1.4],
       [1.7],
       [1.4],
       [1.5],
       [1.4],
```

```
[28] y=df['PetalWidthCm'].to_numpy()
     y

array([0.2, 0.2, 0.2, 0.2, 0.2, 0.4, 0.3, 0.2, 0.2, 0.1, 0.2, 0.2, 0.1,
       0.1, 0.2, 0.4, 0.4, 0.3, 0.3, 0.3, 0.2, 0.4, 0.2, 0.5, 0.2, 0.2,
       0.4, 0.2, 0.2, 0.2, 0.2, 0.4, 0.1, 0.2, 0.1, 0.2, 0.2, 0.1, 0.2,
       0.2, 0.3, 0.3, 0.2, 0.6, 0.4, 0.3, 0.2, 0.2, 0.2, 0.2, 1.4, 1.5,
       1.5, 1.3, 1.5, 1.3, 1.6, 1. , 1.3, 1.4, 1. , 1.5, 1. , 1.4, 1.3,
       1.4, 1.5, 1. , 1.5, 1.1, 1.8, 1.3, 1.5, 1.2, 1.3, 1.4, 1.4, 1.7,
       1.5, 1. , 1.1, 1. , 1.2, 1.6, 1.5, 1.6, 1.5, 1.3, 1.3, 1.3, 1.2,
       1.4, 1.2, 1. , 1.3, 1.2, 1.3, 1.3, 1.1, 1.3, 2.5, 1.9, 2.1, 1.8,
       2.2, 2.1, 1.7, 1.8, 1.8, 2.5, 2. , 1.9, 2.1, 2. , 2.4, 2.3, 1.8,
       2.2, 2.3, 1.5, 2.3, 2. , 2. , 1.8, 2.1, 1.8, 1.8, 1.8, 2.1, 1.6,
       1.9, 2. , 2.2, 1.5, 1.4, 2.3, 2.4, 1.8, 1.8, 2.1, 2.4, 2.3, 1.9,
       2.3, 2.5, 2.3, 1.9, 2. , 2.3, 1.8])
```


כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

ה-X הוא מערך של עמודה אחת ו-150 שורות וה-y הוא מערך ווקטורי נטול כיוון עם 150 איברים. עבודה עם מערכי numpy היא יעילה יותר (מ-Pandas Series ו-Pandas DataFrame) ובחלק מהמקרים הספריות דורשות עבודה עם מערכי numpy ולכן רצוי להתרגל תמיד להגדיר את המשתנים כמערכי numpy.

יש להקים אובייקט ממחלקת **LinearRegression** : reg = LinearRegression()

לאובייקטים יש תכונות מסוימות ופעולות מסוימות. אחת הפעולות של אובייקט ממחלקה זו היא fit שמחשבת את מקדמי הרגרסיה $(w\ ,b)$ היעילים ביותר:

```
reg = LinearRegression()
reg.fit(X,y)

print ('w=',reg.coef_)
print ('b=',reg.intercept_)
```

```
w= [0.41641913]
b= -0.3665140452167275
```

כאשר הפרמטר הראשון (X) הוא המשתנה ממנו יש לחזות והפרמטר השני (y) הוא המשתנה אותו יש לחזות.

על מנת לראות את תוצאת החישוב, יש להדפיס את תכונת reg.coef_ (מקדם) לקבלת w ואת תכונת reg.intercept_ (חותך) לקבלת b. בהדפסה ניתן לראות ש-w הוא ווקטור ו-b הוא מספר.

לאחר שמבצעים שלב האימון, ניתן לעבור לשלב החיזוי:

```
reg.predict([[3],[5],[7]])
```

```
array([0.88274335, 1.71558162, 2.54841988])
```

.

הפעולה predict. מבצעת את החיזוי. בדוגמא כאן מבצעים 3 תחזיות של PetalWidthCm לפי תכונה אחת של PetalLengthCm כפי שאימנתם אותו בפעולה ה-fit. פעולת החיזוי היא פשוט הכפלת כל אחד מהמספרים [3],[5],[7] ב-w שחושב באימון והוספה ה-b שחושב באימון.

בצעו את פעולת score. שנותנת הערכת ביצועים לתהליך הלמידה לפי מדד r^2. תחום התוצאות של הביצועים הוא 0÷1 (לא כמו מדד הקורלציה שהתחום שלו הוא 1÷1-) כאשר 0 הוא הביצוע הכי גרוע (תיאורטית, אם יש טעות באלגוריתם, התוצאה יכולה להיות גם שלילית, אבל לא נכנס לזה עכשיו) ו-1 הוא ביצוע מושלם:

```
reg.score(X,y)
```

```
0.9269012279220037
```


משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

ניתן לראות שביצועי החיזוי כאן הם די טובים.

בצעו המחשה גרפית של פיזור נקודות האמון והעברת הישר שיצר תהליך האימון:

```
[49] sns.scatterplot(data=df,x='PetalLengthCm',y='PetalWidthCm');
     r = np.array([[X.min()],[X.max()]])
     plt.plot(r,reg.predict(r),color='red');
     plt.plot(r,reg.predict(r),'ro');
```

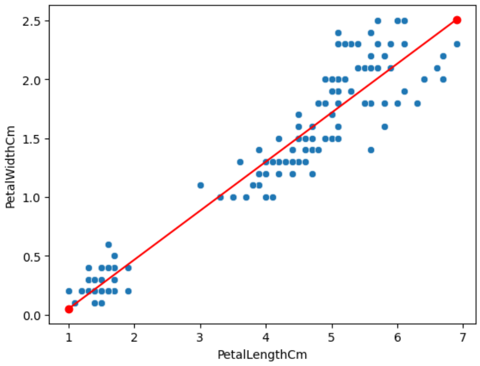

השורה הראשונה משרטטת את הפיזור של שתי התכונות.

השורה השנייה מוצאת את שני ערכי הקצה של הציר האופקי (PetalLengthCm).

השורה השלישית (או הרביעית) מחשבת את הערך האנכי של שני ערכי הקצה (באמצעות הפעולה predict(r)) ומשרטטת את הישר האדום בין שתי נקודות הקצה.

השורה הרביעית משרטטת את שתי נקודות הקצה האדומות.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

חיזוי הכולל מאפיינים מרובים

לאחר שהעכרתם את התשתית של אימון וחיזוי על בסיס מאפיין בודד, תוכלו להרחיבו לאימון וחיזוי על בסיס מספר מאפיינים.

בצעו אימון על SepalLengthCm','PetalLengthCm','SepalWidthCm במטרה לחזות את PetalWidthCm .

```
X=df[['SepalLengthCm','SepalWidthCm','PetalLengthCm']].to_numpy()
X
```

```
array([[5.1, 3.5, 1.4],
       [4.9, 3. , 1.4],
       [4.7, 3.2, 1.3],
       [4.6, 3.1, 1.5],
       [5. , 3.6, 1.4],
       [5.4, 3.9, 1.7]
```

```
y=df['PetalWidthCm'].to_numpy()
y
```

```
array([0.2, 0.2, 0.2, 0.2, 0.2, 0.4, 0.3, 0.2, 0.2, 0.1, 0.2, 0.2, 0.1,
       0.1, 0.2, 0.4, 0.4, 0.3, 0.3, 0.3, 0.2, 0.4, 0.2, 0.5, 0.2, 0.2,
       0.4, 0.2, 0.2, 0.2, 0.2, 0.4, 0.1, 0.2, 0.1, 0.2, 0.2, 0.1, 0.2,
       0.2, 0.3, 0.3, 0.2, 0.6, 0.4, 0.3, 0.2, 0.2, 0.2, 0.2, 1.4, 1.5,
       1.5, 1.3, 1.5, 1.3, 1.6, 1. , 1.3, 1.4, 1. , 1.5, 1. , 1.4, 1.3,
       1.4, 1.5, 1. , 1.5, 1.1, 1.8, 1.3, 1.5, 1.2, 1.3, 1.4, 1.4, 1.7,
       1.5, 1. , 1.1, 1. , 1.2, 1.6, 1.5, 1.6, 1.5, 1.3, 1.3, 1.3, 1.2,
       1.4, 1.2, 1. , 1.3, 1.2, 1.3, 1.3, 1.1, 1.3, 2.5, 1.9, 2.1, 1.8,
       2.2, 2.1, 1.7, 1.8, 1.8, 2.5, 2. , 1.9, 2.1, 2. , 2.4, 2.3, 1.8,
       2.2, 2.3, 1.5, 2.3, 2. , 2. , 1.8, 2.1, 1.8, 1.8, 1.8, 2.1, 1.6,
       1.9, 2. , 2.2, 1.5, 1.4, 2.3, 2.4, 1.8, 1.8, 2.1, 2.4, 2.3, 1.9,
       2.3, 2.5, 2.3, 1.9, 2. , 2.3, 1.8])
```

בצעו את שלב האימון:

```
reg = LinearRegression()
reg.fit(X,y)

print ('w=',reg.coef_)
print ('b=',reg.intercept_)
```

```
w= [-0.21027133  0.22877721  0.52608818]
b= -0.2487235860244532
```

בהדפסה ניתן לראות שהפעם w הוא ווקטור עם 3 רכיבים ו-b הוא גם כאן מספר.

עברו לשלב החיזוי עבור 3 דוגמאות:

```
reg.predict([[1,2,3],[3,4,5],[5,6,7]])
```

```
array([1.57682405, 2.66601218, 3.75520031])
```

בצעו הערכת ביצועים לתהליך הלמידה לפי מדד r^2:

```
reg.score(X,y)
```

```
0.9380481344518986
```

ניתן לראות שביצועי החיזוי כאן הם קצת יותר טובים מאשר בחיזוי הקודם (0.9269012279220037) לפי מאפיין בודד.

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

תרגיל השלמת קוד Linear regression

בצעו את התרגיל Linear regression ex1. יש להשלים את הקוד המתאים במקומות שרשום "?".

פתחו את הקישור למחברת ובצעו File/Save a copy in drive (על מנת לשמור אצלכם את המחברת עם השינויים שלכם).

הצעה לפתרון התרגיל נמצא במחברת Linear regression ex1-didi.ipynb.

הוראת assert X.shape==(150, 1) בודקת האם ה-X שנוצר קודם הוא בעל מבנה (150,1). אם לא, המערכת תודיע על שגיאה.

ההוראה X[:5] היא הוראת slicing - לקחת את 5 האיברים הראשונים מהמערך X. הצורה הכללית של ההוראה היא var(i1:i2) כאשר i1 הוא אינדקס האיבר הראשון שיש להציג ו-i2 הוא אינדקס האיבר שעד אליו, **לא כולל אותו**, יש לקחת. כאשר i1=0 (האיבר הראשון במערך) ניתן להשאיר אותו ריק (כמו בדוגמא כאן). כאשר רוצים לקחת עד סוף המערך, יש להשאיר את i2 ריק.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

פונקציית המחיר ו-gradient descent

בשלב זה נלמד כיצד לנתח באופן אנליטי "מהו הישר הטוב ביותר" לחיזוי לינארי לפי פיזור של נתוני אימון ולמצוא את הפרמטרים של הישר הזה בשיטה הנקראת gradient descent.

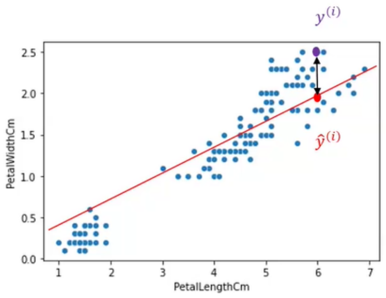

בהינתן סט של m דוגמאות $(x^{(i)},y^{(i)})$

$x^{(i)}$ - ערכי דגימות של המשתנה הבלתי תלוי

$y^{(i)}$ – ערכי דגימות המשתנה התלוי בהתאמה

ובהינתן מודל רגרסיה $\hat{y} = w \cdot x + b$

נגדיר את שגיאת החיזוי על הדוגמא ה-(i):

$$l^{(i)} = (\hat{y}^{(i)} - y^{(i)})^2 = (w \cdot x^{(i)} + b - y^{(i)})^2$$

שגיאת החיזוי מסומנת ב-l (Loss).

הסיבות להגדרת שגיאת חיזוי כריבוע ההפרש:

- התייחסות לערך המוחלט של השגיאה תוך התעלמות מכיוונה, וזאת על מנת למנוע מצב בו חלק מהשגיאות יבוטלו ע"י שגיאות אחרות בעלות סימן הפוך.
- מתן משקל רב יותר (לעומת, למשל הגדרת השגיאה כערך מוחלט של ההפרש) **לשגיאות גדולות**.

פונקציית המחיר J (Cost) מוגדרת כממוצע של שגיאות החיזוי של כל m הדוגמאות באופן הבא:

ובהינתן מודל רגרסיה $\hat{y} = w \cdot x + b$

נגדיר את שגיאת החיזוי על כל סט נתוני האימון:

$$J = \frac{1}{m}\sum_{i=1}^{m} l^{(i)} = \frac{1}{m}\sum_{i=1}^{m}(\hat{y}^{(i)} - y^{(i)})^2 = \frac{1}{m}\sum_{i=1}^{m}(w \cdot x^{(i)} + b - y^{(i)})^2$$

j כמובן לא יכול להיות מספר שלילי. המטרה היא למזער את J. הישר הכי טוב הוא זה שייתן את ערך ה-j הכי נמוך והערך הכי נמוך שיכול להיות הוא 0.

מהגדרת פונקציית המחיר נובע שפונקציית המחיר $J(w,b) = \frac{1}{m}\sum_{i=1}^{m}(w \cdot x^{(i)} + b - y^{(i)})^2$ היא פונקציה ריבועית של w ו-b. באופן כללי, לכל פונקציה ריבועית, מציאת המינימום בדרך של איטרטיבית מתבצעת באופן הבא:

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

הכללה - התקדמות בכיוון הנגזרת

בחרנו x התחלתי. אנחנו רוצים לקדם את x לכיוון נקודת המינימום.

כדאי לעדכן את x (להגדיל או להקטין) נגד כיוון הנגזרת

כלומר לכיוון $-\frac{df(x)}{dx}$

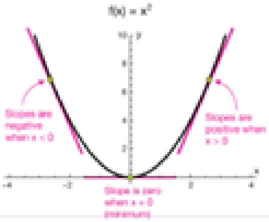

אלגוריתם gradient descent

- על מנת למצוא את נקודת המינימום של פונקציה J(w):
  - נגריל נקודת התחלה w_0
  - נקדם את ערך w לפי הנוסחה:

$$w \leftarrow w - \alpha \frac{\partial J(w)}{\partial w}$$

- α – קצב הלמידה
- $\frac{\partial J(w)}{\partial w}$ - נגזרת הפונקציה

יש להיזהר בבחירת קצב הלמידה α. בחירת קצב נמוך מידי עלול לדרוש מספר גבוה מידי של איטרציות (=משך זמן חישוב גבוה מידי) וקצב גבוה מידי עלול לגרום לקפיצה ל"צד השני" של הפרבולה והתרחקות מנקודת המינימום. לאחר כל איטרציה של חישוב נגזרת לפי w וקידום w, יש לבצע איטרציה של חישוב נגזרת לפי b וקידום b.

בצעו את התרגיל Linear regression ex2 (cost function & Pandas DF) שנמצא ב-קישורים יחידה1/יחידה1/classroom. יש להשלים את הקוד המתאים במקומות שרשום "?".

פתחו את הקישור למחברת ובצעו File/Save a copy in drive (על מנת לשמור אצלכם את המחברת עם השינויים שלכם).
הצעה לפתרון התרגיל במחברת כאן: Linear regression ex2-didi.ipynb.

ההוראה df.head(n) מציגה את n השורות הראשונות של טבלת המשתנים df. עבור n=0 תוצג רק שורת הכותרות של הטבלה. כאשר לא מצוין n (df.head()), תוצגנה 5 השורות הראשונות של הטבלה.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

הוספת ממד למערך קיים:

```
print(X.shape)
X = np.expand_dims(X,axis=1) #expand dimensions
X.shape
```

```
(150,)
(150, 1)
```

יצירת טבלה עם כותרות עמודות ושורת ממוצע ממערכי ווקטורים בעלי אורך זהה באמצעות pandas

```
pd.options.display.float_format = '{:,.5f}'.format
df1 = pd.DataFrame(data={'x': X, 'y':y, 'y_hat':y_hat, 'dy':dy, 'dy_sq':dy_sq})
df1.loc["Mean"] = df1.mean()
df1
```

	x	y	y_hat	dy	dy_sq
0	1.40000	0.20000	0.21647	-0.01647	0.00027
1	1.40000	0.20000	0.21647	-0.01647	0.00027
2	1.30000	0.20000	0.17483	0.02517	0.00063
3	1.50000	0.20000	0.25811	-0.05811	0.00338
4	1.40000	0.20000	0.21647	-0.01647	0.00027
...	...	...	...	...	...
146	5.00000	1.90000	1.71558	0.18442	0.03401
147	5.20000	2.00000	1.79887	0.20113	0.04046
148	5.40000	2.30000	1.88215	0.41785	0.17460
149	5.10000	1.80000	1.75722	0.04278	0.00183
Mean	3.75867	1.19867	1.19867	-0.00000	0.04229

151 rows × 5 columns

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

רגרסיה ליניארית חד/רב ממדית

יש לטעון את המחברת KC house data ולבצע את התרגיל הבא:

- חשבו רגרסיה לינארית חד ממדית של מחיר הדירה ביחס לשטחה
- חשבו רגרסיה לינארית חד ממדית של מחיר הדירה ביחס למספר החדרים
- חשבו רגרסיה לינארית דו ממדית של מחיר הדירה ביחס לשטח ולמספר החדרים
- חשבו רגרסיה לינארית רב ממדית של מחיר הדירה ביחס לכל המשתנים פרט ל:

```
['id','date','zipcode']
```

פתחו את הקישור למחברת KC house data ובצעו File/Save a copy in drive (על מנת לשמור אצלכם את המחברת עם השינויים שלכם).

הצעה לפתרון התרגיל מוצג במחברת: KC House data-didi Targil1.ipynb

שימו לב ל-score (הערכת ביצועים של הרגרסיה לפי מדד r^2) שהתקבל עבור כל אחת מהרגרסיות.

- בסעיף האחרון, בפעולת ה-df.drop לפני הגדרת ה-X בחיזוי המחיר ביחס לכל המשתנים פרט ל- id, date, zipcode יש לזכור להסיר גם את עמודת ה-price.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

רגרסיה לוגיסטית

הערכת ביצועים של מסווג

להלן קישור לסרטון הסבר בנושא של הערכת ביצועים של מסווג.

MNIST database – (*Modified National Institute of Standards and Technology*) בסיס נתונים של הספרות 0-9 בכתב יד. בסיס הנתונים מכיל 70,000 דוגמאות של ספרות מסווגות - 60,000 לאימון ו-10,000 לבדיקה.

בסיס הנתונים מכיל תמונות של הספרות בגודל 28x28 פיקסלים grey scale.

כל פיקסל הוא מספר בתחום 0-255 שמתאר את רמת ה"לבן" של הפיקסל.

על מנת לזהות את הספרה, מספקים למחשב מערך של 28x28 (או וקטור של 1x784) מספרים בתחום 0-255.

ברגרסיה הלינארית מנסים לחזות משתנה רציף (מחירים, לחץ דם, משקל...). בזיהוי ספרות מנסים לזהות class/מחלקה ולכן הרגרסיה הלינארית לא מתאימה לשימוש כאן ויש להשתמש בתהליך אחר, רגרסיה לוגיסטית, שמתאים לבעיות של סיווג למחלקות ולא של תחזית משתנה רציף.

לפני שלומדים על רגרסיה לוגיסטית, יש להבין וללמוד את מושגי סיווג והערכת ביצועים של מסווג מאומן.

תקציר מהסרטון:

הערכת ביצועים של מסווג מאומן – השוואת תוצאות החיזוי של דוגמאות שלא השתתפו בתהליך האימון עם תגיות האמת שבבסיס הנתונים.

מטריצת בלבול – תיאור ביצועי המסווג באמצעות מטריצה עם התגיות האמיתיות של כל הדוגמאות שנבדקו בציר אחד (מקובל, האנכי) והתגיות שחזה המסווג בציר השני (האופקי).

- על האלכסון הראשי של המטריצה נרשמים כמות הסיווגים הנכונים לכל תגית.
- מחוץ לאלכסון הראשי נרשמים כמויות הסיווגים הלא נכונים לכל הצירופים של תגית אמיתית/תגית חזויה.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

Accuracy – מספר הדוגמאות שנחזו נכון (סכום האברים באלכסון הראשי) חלקי מספר הדוגמאות הכולל (סכום האברים בכל המטריצה).

ההגדרה הזו של Accuracy היא בעייתית - כאשר הבדיקה מתבצעת על סט לא מאוזן, כמו בדוגמה שבסרטון של "זיהוי אריות" (בסט של 1 אריה + 1000 חיות אחרות) שבסרטון, מקבלים דיוק גבוה של 95% עם חיזוי של 51 אריות כאשר רק אחד מהם נכון. זה גם מה שיקרה אם בודקים מחלה על מדגם של מעט מאוד אנשים חולים והרוב בריאים.

מקרה פרטי של מסווג בעל שתי אפשרויות (=תגיות) בלבד P (Positive) ו-N (Negative) נקרא גלאי. בדרך כלל, מגדירים את האפשרות שחשוב לגלות אותה (נשא קורונה, אור אדום ברמזור...) כ-Positive ואת האפשרות האחרת כ-Negative). מטריצת הבלבול של מסווג בעל שתי אפשרויות כוללת 4 תאים:

TP – TruePositive – חיזוי P כ-P.

TN – TrueNegative – חיזוי N כ-N.

FN – FalseNegative (זה למעשה Miss Detection) – חיזוי P כ-N.

FP – FalsePositive – חיזוי N כ-P.

Accuracy – מספר החיזויים הנכונים חלקי מספר החיזויים הכולל $\frac{TP+TN}{TP+TN+FN+FP}$

Precision – מספר חיזוי החיובים כחיוביים חלקי מספר חיזוי החיוביים הכולל $\frac{TP}{TP+FP}$.

Recall – מספר חיזוי החיובים כחיוביים חלקי מספר החיוביים הכולל $\frac{TP}{TP+FN}$

עבור הדוגמא של זיהוי אריות שבסרטון:

TP=1, TN=950, FN=0, FP=50

Accuracy – $\frac{TP+TN}{TP+TN+FN+FP} = \frac{1+950}{1+950+0+50} = \frac{951}{1000} = 95.1\%$

Precision – $\frac{TP}{TP+FP} = \frac{1}{1+50} = \frac{1}{51} \approx 2\%$

Recall – $\frac{1}{1+0} = 100\%$

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
MoreTech מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

מההגדרות ודוגמת האריה אנו למדים שהשימוש ב-Precision/Recall עדיף על השימוש ב-Accuracy. לפי אופי האפליקציה ניתן לקבוע מהו המדד החשוב יותר Precision או Recall.

מדד F1 הוא מדד של ממוצע הרמוני של Precision ו-Recall:

$$F1 = \frac{2 * precision * recall}{precision + recall}$$

מדד F1 עבור זיהוי אריות שבסרטון:

$$F1 = \frac{2 * {}^{1}/_{51} * 1}{\frac{1}{51} + 1} = \frac{{}^{2}/_{51}}{{}^{52}/_{51}} = {}^{2}/_{52} \approx 3.8\%$$

מדידת ביצועים של מסווג – תרגיל

קישור לדף העבודה וקישור לפתרון.

רגרסיה לוגיסטית – הגדרה

רגרסיה לוגיסטית היא אלגוריתם סיווג המחשב את ההסתברות שדוגמא לא ידועה שייכת לכל אחד מהסוגים. הרגרסיה הלוגיסטית מסווגת לשתי מחלקות בלבד (0/1, אריה/לא אריה...).

תכונות רלוונטיות לצורך מטרת הרגרסיה הלוגיסטית:

- קיימת עבור כל הערכים של Z.
- רציפה עם נזרות רציפות (לצורך אלגוריתם Gradient Descent)

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

- תחומה בין 0 ל-1 (לביטוי הסתברות).

הסיווג מתבצע על ידי התאמת קו רגרסיה לוגיסטית:

אלגוריתם רגרסיה לוגיסטית

הסיווג מבוצע על ידי התאמת קו רגרסיה לוגיסטית (סיגמואיד)

$$\hat{y} = \sigma(wx + b)$$

נסווג את x לסוג 0 אם $\hat{y} < 0.5$
ולסוג 1 אם $\hat{y} \geq 0.5$

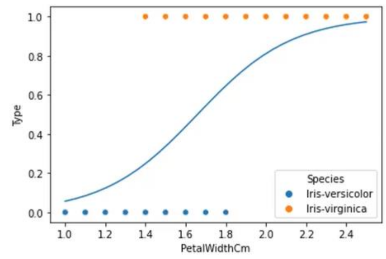

שימו לב :

x – הוא גודל רציף בדרך כלל (מידות עלי הפרח, שטח הדירה...). לעיתים הוא בדיד (מספר החדרים בדירה, ציון במבחן).

w,b – גדלים רציפים. ולכן (גם עבור x בדיד), גם Z – גודל רציף. ולכן, גם $\hat{y}$ הוא גודל רציף (בין 0 ל-1).

ה-predicted y הוא גודל בדיד (ברגרסיה לוגיסטית - של 2 מצבים בלבד). יש דרך לסווג גם ליותר מ-2 מחלקות ע"י ביצוע מספר רגרסיות לוגיסטיות אבל לא נכנס לזה במסמך זה.

בחיזוי עם מאפיין בודד (PetalWidthCm בשקף 4), התהליך ייתן נקודת הפרדה בה ה-z=0 (הסתברות 50%).

ריבוי מאפיינים:

$$\hat{y} = \sigma(w_1x_1 + w_2x_2 + \cdots + w_nx_n + b)$$

נסווג את x לסוג 0 אם $\hat{y} < 0.5$
ולסוג 1 אם $\hat{y} \geq 0.5$

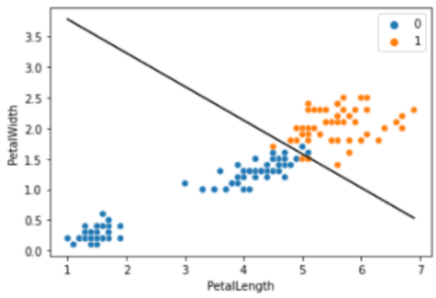

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

בחיזוי עם 2 מאפיינים (PetalLengthCm ו-PetalWidthCm בשקף 5), התהליך ייתן ישר הפרדה עליו ה-z=0 (הסתברות 50%).

בחיזוי עם 3 משתנים בלתי תלויים, התהליך ייתן מישור הפרדה עליו ה-z=0 (הסתברות 50%).

הסבר כיצד נוצר קו ישר (בשקף 5) למרות שהסיגמואיד אינו פונקציה לינארית:

x_1 - PetalWidthCm

x_2 - PetalLengthCm

$$z = w_1 * x_1 + w_2 * x_2 + b$$

המשוואה האחרונה היא משוואה של מישור במרחב $(x_1; x_2; z)$ קו ההפרדה הוא המקום בו $z = 0$ (הסתברות 0.5) כלומר, ישר החיתוך של המישור הזה עם מערכת הצירים המישורית $(x_1; x_2)$:

$$w_1 * x_1 + w_2 * x_2 + b = 0$$

$$w_1 * x_1 = -w_2 * x_2 - b$$

$$x_1 = -\frac{w_2}{w_1} * x_2 - \frac{b}{w_1}$$

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

סיווג על ידי רגרסיה לוגיסטית – תרגיל

Image	X_1 (red)	X_2 (blue)	$z = w_1 \cdot x_1 + w_2 \cdot x_2 + b$	$\hat{y} = \sigma(z)$	סוג 0=יער 1=עיר
	153	173			
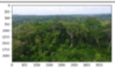	93	83			
	81	124			
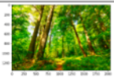	90	18			

נתונות תמונות בעלות שני מאפיינים:
- x1 ממוצע האדום בתמונה
- x2 ממוצע הכחול בתמונה

נתון מסווג מסוג רגרסיה לוגיסטית בעל הפרמטרים הבאים:
- w1=0.06
- w2=0.04
- b=-10

סווגו את התמונות הבאות:

קישור לקובץ הפתרון ב-excel:

w1=	0.06
w2=	0.04
b=	-10

x1(RED)	x2(BLUE)	z=w1*x1+w2*x2+b	y^=σ(Z)	סוג 0=יער 1=עיר
153	173	6.1	0.997762151	1
93	83	-1.1	0.249739894	0
81	124	-0.18	0.455121108	0
90	18	-3.88	0.020232997	0

תמונות 1 ו-4 זוהו נכון ברמת וודאות גבוהה (ה-y^ קרובים מאוד ל-1 או ל-0).

תמונה 2 זוהתה נכון כיער ברמת וודאות בינונית (0.25 קרוב יותר ל-0).

תמונה 3 זוהתה לא נכון כיער ברמת וודאות מאוד נמוכה (0.455 קרוב מאוד ל-0.5).

קישור לקובץ הפתרון בפייתון.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

תהליך האימון ברגרסיה לוגיסטית

תהליך האימון ברגרסיה לוגיסטית דומה לזה ברגרסיה ליניארית:

- רושמים פונקציית מחיר.
- גוזרים את פונקציית המחיר.
- מוצאים את נקודת המינימום בשיטת gradient descent.

פונקציית המחיר - binary cross entropy

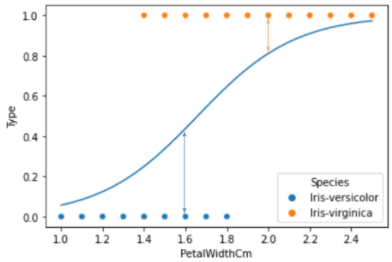

$$l^{(i)} = -y^{(i)} \log \hat{y}^{(i)} - (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})$$

$$J = \frac{1}{m} \sum_{i=1}^{m} l^{(i)}$$

פונקציית המחיר הזו נבחרה כי משיקולים סטטיסטיים של most likelihood (מחוץ לתחום הלמידה שלנו כאן) היא עובדת הכי טוב עבור בעיות החלטה בין שני class.

האם המופעים של (i) בפונקציית המחיר הזו מציינים אינדקס או חזקה?

שימו לב! – ה-log בנוסחאות כאן הוא לפי בסיס הלוגריתם הטבעי (ולא בבסיס 10).

ה-$y^{(i)}$ יכול לקבל רק את הערכים 0 או 1 ולכן:

כאשר $y^{(i)} = 0$: $l^{(i)} = -\log(1 - \hat{y}^{(i)})$

כאשר $y^{(i)} = 1$: $l^{(i)} = -\log \hat{y}^{(i)}$

ויזואליזציה של פונקציית המחיר

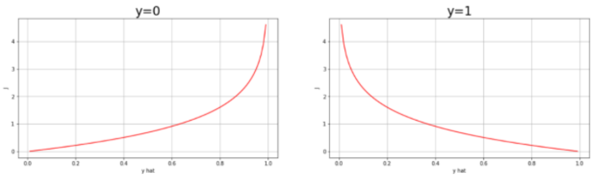

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

הפקולטה לחינוך למדע וטכנולוגיה, הטכניון, מכון טכנולוגי לישראל, חיפה 320003
E-mail: Moretech@ed.technion.ac.il טל: 73-3783146 972+
https://moretech.technion.ac.il

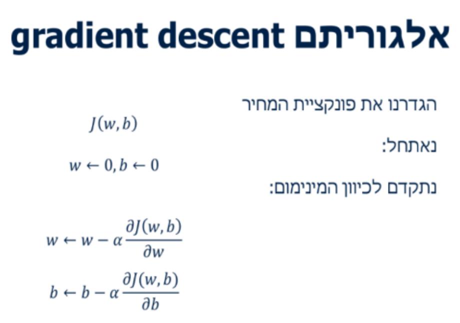

גזירת פונקציית המחיר ומציאת נקודת המינימום מתבצעת בשיטת gradient descent בצורה דומה לרגרסיה לינארית כאשר ההבדל הוא בנגזרות עצמן עקב הסיגמואיד ב-

$\hat{y} = \sigma(w_1 x_1 + w_2 x_2 + \cdots + w_n x_n + b)$ **וגם ה-** $l^{(i)} =$

$l^{(i)} = -\log \hat{y}^{(i)}$ **או** $-\log(1 - \hat{y}^{(i)})$ **?**

גם כאם חשוב לבחור מקדם קצב למידה (α) עם ערך לא גבוה מידי על מנת למנוע "התבדרות לצד השני".

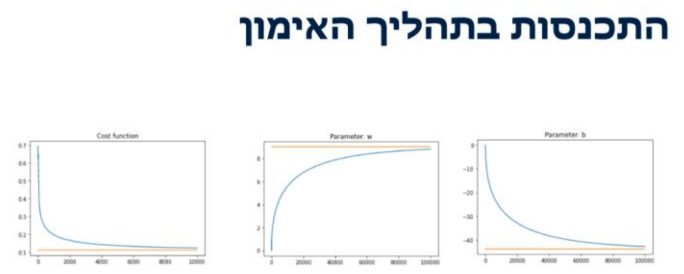

בתהליך האימון ניתן לראות התכנסות של ה-w וה-b ושאיפה למינימום של פונקציית המחיר.

רגרסיה לוגיסטית ב-sklearn

- יש לייבא ספריית LogisticRegresion.
- יש לבחור את העמודות הרלוונטיות בטבלת הנתונים עבור המאפיינים עליהם אנו רוצים לבצע קלסיפיקציה – למשל, 4 עמודות האורך/רוחב של העלים.
- בבחירת התנאי הלוגי יש לבחור את עמודת הסיווג בטבלת הנתונים ולבצע תנאי השוואה בוליאנית של ערכה לסוג שמוגדר כ"1" לוגי. התוצאה y יכולה להיות 0 או 1 (לכל אחת מהדוגמאות/שורות שבטבלת הנתונים).

משרד החינוך המזכירות הפדגוגית אגף א' למדעים | מנהל החינוך הטכנולוגי | מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט | מור-טק | הטכניון מכון טכנולוגי לישראל | הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

- מגדירים מסווג ומבצעים פעול fit שמחשבת
את וקטור ה-w והמספר b.

קישור לדוגמא לרגרסיה לוגיסטית ב-sklearn עם בסיס הנתונים של הפרחים לחיזוי האם סוג הפרח הוא "Iris-virginica" לפי המאפיינים 'PetalLengthCm','PetalWidthCm' .

- הפקודה ()df['Species'].unique מציגה את הסוגים הקיימים.
- הפקודה ()df['Species'].nunique מציגה מספר הסוגים הקיימים.
- הפקודה ()df['Species'].value_counts מציגה כמה יש מכל סוג.
- שימו לב! ברגרסיה לוגיסטית יש להוסיף 0 בתוך הסוגרים של חילוץ המקדמים = w_sk reg.coef_[0]. הסיבה לכך היא שברגרסיה לוגיסטית ניתן לבצע מספר סיווגים ברגרסיה אחת שמחזירה מערך של מקדמים עבור כל מאפיין. אנחנו לומדים בשלב זה סיווג בינרי בלבד.

```
reg.coef_
array([[2.77759875, 2.38552765]])
```

בתא ניתן לראות (לפי ה-"[[..]]") שה-reg.coef_ הוא מערך של מערכים.

- ה-score נותן את ה-Accuracy.
- ההוראה ;ConfusionMatrixDisplay.from_estimator(reg, X, y) מציגה את מטריצת הבלבול של המסווג reg המאפיינים X והסוג y.

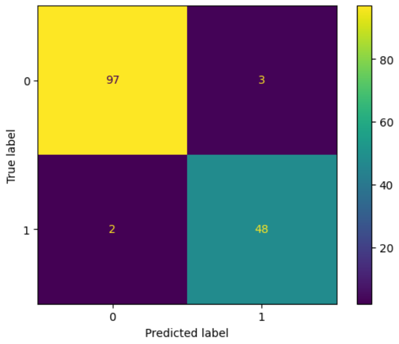

  - ניתן לראות 3 אירועי FN ו-2 אירועי FP.

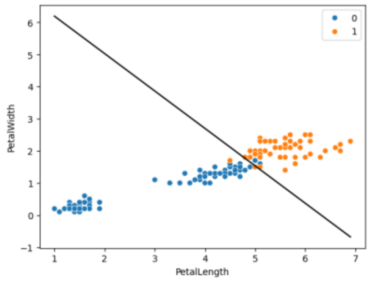

- הצגה ויזואלית של פיזור המאפיינים וישר הסיווג.
  - mg ו-bg הם השיפוע והחיתוך של ישר הסיווג.

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

- ניתן להבחין בשני אירועי FN כנקודות כחולות (0) באזור הכתום (1) ו-2-4 אירועי FP כנקודות כתומות (1) באזור הכחול (0).

רגרסיה לוגיסטית ב-sklearn – תרגיל

- טענו את המחברת של Penguin dataset.
- נסו לחזות 'df['species']=='Adelie על פי 'bill_length_mm', 'bill_depth_mm'
- חשבו את מדד accuracy
- חשבו את מטריצת הבלבול
- שרטטו את קו ההפרדה

הצעה לפתרון מוצג במחברת: Penguin dataset_Targil_2.ipynb.

פקודת ()df.dropna מסירה את כל השורות בהם חסרים נתונים(NaN).

בבסיס הנתונים הזה יש 4 עמודות של מאפיינים (2 אורכים, עומק, מסה) ו-3 עמודות של תגיות (סוג(x3), אי(x3), מין(x2)) .

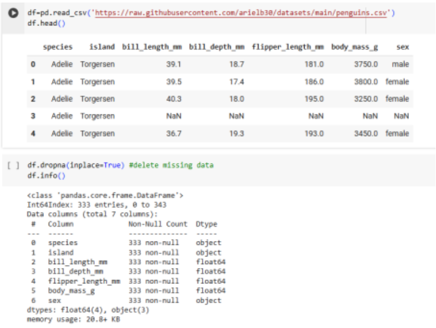

```
df=pd.read_csv('https://raw.githubusercontent.com/arielb30/datasets/main/penguins.csv')
df.head()
```

	species	island	bill_length_mm	bill_depth_mm	flipper_length_mm	body_mass_g	sex
0	Adelie	Torgersen	39.1	18.7	181.0	3750.0	male
1	Adelie	Torgersen	39.5	17.4	186.0	3800.0	female
2	Adelie	Torgersen	40.3	18.0	195.0	3250.0	female
3	Adelie	Torgersen	NaN	NaN	NaN	NaN	NaN
4	Adelie	Torgersen	36.7	19.3	193.0	3450.0	female

```
df.dropna(inplace=True) #delete missing data
df.info()
```

```
<class 'pandas.core.frame.DataFrame'>
Int64Index: 333 entries, 0 to 343
Data columns (total 7 columns):
 #   Column             Non-Null Count  Dtype
---  ------             --------------  -----
 0   species            333 non-null    object
 1   island             333 non-null    object
 2   bill_length_mm     333 non-null    float64
 3   bill_depth_mm      333 non-null    float64
 4   flipper_length_mm  333 non-null    float64
 5   body_mass_g        333 non-null    float64
 6   sex                333 non-null    object
dtypes: float64(4), object(3)
memory usage: 20.8+ KB
```

הפקודה
sns.pairplot(data=df.drop(['island','species'],axis=1), hue='sex');
מסירה מבסיס הנתונים את עמודות תגיות "אי" ו"סוג" ומציגה את מטריצת גרפי הפיזור של 16 צירופי זוגות המאפיינים (4 מאפיינים=16 תאים).
באלכסון הראשי (גרף הפיזור של מאפיין עם עצמו) מוצגת היסטוגרמה של כמות המאפיין בחלוקה למין (זכר=כחול, נקבה=כתום).

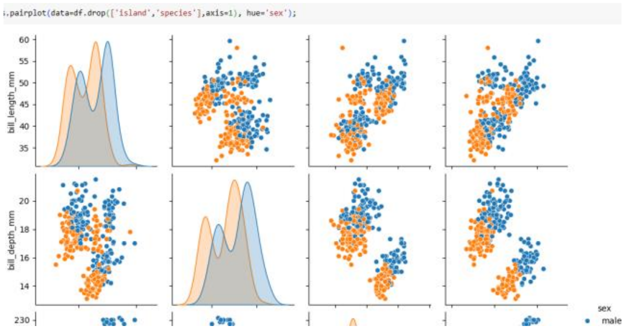

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

הפקודות:

scaler = MinMaxScaler()

X=scaler.fit_transform(X)

מנרמלות את תחומי ערכי המאפיינים לתחום 0-1.

ראו את ערכי X לפני ואחרי הנרמול.

```
X=df[['bill_length_mm', 'bill_depth_mm','flipper_length_mm', 'body_mass_g']].to_numpy()
y= df['species'].to_numpy()
print ("X.shape=",X.shape)
print ("y.shape=",y.shape)
```

```
X.shape= (333, 4)
y.shape= (333,)
```

```
X
```

```
array([[  39.1,   18.7,  181. , 3750. ],
       [  39.5,   17.4,  186. , 3800. ],
       [  40.3,   18. ,  195. , 3250. ],
       ...,
       [  49.6,   18.2,  193. , 3775. ],
       [  50.8,   19. ,  210. , 4100. ],
       [  50.2,   18.7,  198. , 3775. ]])
```

Using MinMaxScaler

```
[23] print('Max: ', X.max())
     print('Min: ', X.min())
     scaler = MinMaxScaler()
     X=scaler.fit_transform(X)
     print('Max: ', X.max())
     print('Min: ', X.min())
```

```
Max:  6300.0
Min:  13.1
Max:  1.0
Min:  0.0
```

```
[24] X
```

```
array([[0.25454545, 0.66666667, 0.15254237, 0.29166667],
       [0.26909091, 0.51190476, 0.23728814, 0.30555556],
       [0.29818182, 0.58333333, 0.38983051, 0.15277778],
       ...,
       [0.63636364, 0.60714286, 0.3559322 , 0.29861111],
       [0.68      , 0.70238095, 0.6440678 , 0.38888889],
       [0.65818182, 0.66666667, 0.44067797, 0.29861111]])
```

הגדרת המאפיינים (X) והתווית (y) לאימון.

ביצוע רגרסיה לוגיסטית.

הדפסת המקדמים (w_sk) והחותך (b_sk) .

Logistic regression with SKLearn

```
[109] X=df[['bill_length_mm','bill_depth_mm']].to_numpy()
      y=1*(df['species']=='Adelie').to_numpy()
      print(X.shape,y.shape)
```

```
(333, 2) (333,)
```

```
reg = LogisticRegression()
reg.fit(X,y)
w_sk = reg.coef_[0]
b_sk = reg.intercept_[0]
print(w_sk,b_sk)
```

```
[-1.37826428  1.98506245] 24.297550666550585
```


הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים | הטכניון מכון טכנולוגי לישראל | מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים | מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט | מנהל החינוך הטכנולוגי | משרד החינוך המזכירות הפדגוגית אגף א' למדעים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

חישוב מדד Accuracy

```
[112] reg.score(X,y) #compute accuracy

      0.9819819819819819
```

מטריצת הבלבול

```
[113] ConfusionMatrixDisplay.from_estimator(reg, X, y);
```

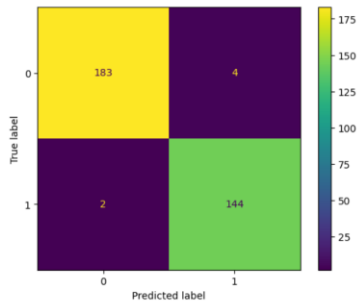

קו ההפרדה על גרף הפיזור

```
plt.xlabel('PetalLength')
plt.ylabel('PetalWidth')
mg = -w_sk[0]/w_sk[1]
bg = -b_sk/w_sk[1]
xg = np.array([X[:,0].min(),X[:,0].max()])
yg = mg * xg + bg
sns.scatterplot(x=X[:,0],y=X[:,1],hue=y)
plt.plot(xg,yg,color="black");
```

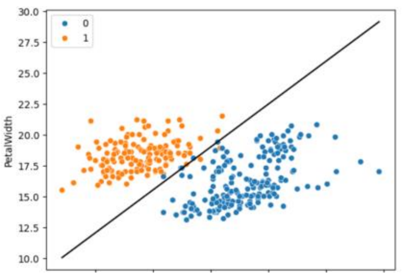

בקישור מודגמת הבעיה של הפרדה של המין Iris-versicolor לפי המאפיינים PetalLengthCm,PetalWidthCm שמפוזר בתוך שני המינים האחרים ולכן קשה/לא ניתן לחזות אותו באמצעות ישר חיתוך בודד. מודגם גם הפתרון באמצעות שתי רגרסיות שיוצרות שני ישרים המפרידים בין שלשת המינים.

הדוגמה הזו מהווה מוטיבציה לפתרון בעיות הפרדה באמצעות למידה עמוקה / רשת נוירונים שהיא למעשה ריבוי מובנה של רגרסיות לוגיסטיות שיוצר גבולות שמחלקות את מרחב הפיזור של המאפיינים לתת-מרחבים נפרדים עבור כל תגית שנדרש לחזות כאשר מרחב הפיזור ותתי המרחבים הנפרדים הם בעלי ממד זהה. וזאת, לעומת הרגרסיה הלוגיסטית הבודדת שיוצרת את הפרדה לשני תתי מרחב בלבד.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

למידה עמוקה - רשת נוירונים

טעינת dataset לגוגל Colab

להלן קישור לרשימה של 3 סרטונים על דרכים שונות לטעינת dataset לגוגל Colab. ניתן להשתמש בידע הזה במסגרת ביצוע פרויקט.

- מומלץ לבצע את החיפוש וההעלאה לפי ההנחיות ב-"from google drive…" (הקישור הראשון). הסרטון "from github…" הוא לבעלי github. הסרטון "directly from Kaggle…" הוא למתקדמים.
  - הורידו ה-dataset ממאגר בסיסי הנתונים (למשל, Kaggle) לכונן המקומי, העבירו ל-google drive וטענו ל-Colab.
  - הרשמו וכנסו ל-Kaggle עם חשבון גוגל: xxx@gmail.com.
  - חפשו diamonds , בדקו שזה אכן dataset ע"י בחירת לשונית Datasets והורידו למחשב האישי. לחיצה כפולה על קובץ ה-zip אמנם מראה את קובץ ה-diamonds.csv אבל העתקתו לgoogle-drive מסתיימת בתוצאה של קובץ ריק ולכן יש לבצע extract to archive ומשם להעתיק את diamonds.csv אל ה-Drive.
  - העלו ה-dataset למחברת – פותחים מחברת ונותנים לה שם/קישור MyDiamonds,

    לוחצים בסרגל הכלים משמאל על צלמית הקבצים , מקבלים את מבנה התיקיות של

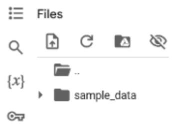

    שרת הלינוק עליו רץ ה-colab , בוחרים בצלמית העלאת ה-drive וזה

    יוצר במחברת את ההוראה

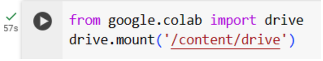

    שהרצתה עם מתן כל ההרשאות

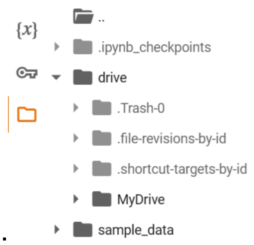

    מודיעה Mounted at /content/drive ומוסיפה למבנה הקבצים את ה-drive .
  - הקובץ diamonds.csv נמצא במחיצת MyDrive. על מנת לייבא אותו יש להוסיף את הקוד הבא:

import pandas as pd

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

מרכז המורים הארצי למקצועות הטכנולוגיים
הפקולטה לחינוך למדע וטכנולוגיה, הטכניון, מכון טכנולוגי לישראל, חיפה 320003
טל: 3783146-73 972+ E-mail: Moretech@ed.technion.ac.il
https://moretech.technion.ac.il

df=pd.read_csv("/content/drive/MyDrive/diamonds.csv")

את הלינק ניתן לקבל ב-copy path שבתפריט של לחיצה ימנית על diamonds.csv:

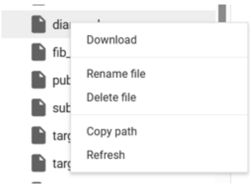

הרצת ה-df:

```
import pandas as pd
df=pd.read_csv("/content/drive/MyDrive/diamonds.csv")
df
```

	Unnamed: 0	carat	cut	color	clarity	depth	table	price	x	y	z
0	1	0.23	Ideal	E	SI2	61.5	55.0	326	3.95	3.98	2.43
1	2	0.21	Premium	E	SI1	59.8	61.0	326	3.89	3.84	2.31
2	3	0.23	Good	E	VS1	56.9	65.0	327	4.05	4.07	2.31
3	4	0.29	Premium	I	VS2	62.4	58.0	334	4.20	4.23	2.63
4	5	0.31	Good	J	SI2	63.3	58.0	335	4.34	4.35	2.75
...	...	...	...	...	...	...	...	...	...	...	...
53935	53936	0.72	Ideal	D	SI1	60.8	57.0	2757	5.75	5.76	3.50
53936	53937	0.72	Good	D	SI1	63.1	55.0	2757	5.69	5.75	3.61
53937	53938	0.70	Very Good	D	SI1	62.8	60.0	2757	5.66	5.68	3.56
53938	53939	0.86	Premium	H	SI2	61.0	58.0	2757	6.15	6.12	3.74
53939	53940	0.75	Ideal	D	SI2	62.2	55.0	2757	5.83	5.87	3.64

53940 rows × 11 columns

למידה עמוקה

בסוף הפרק הקודם ראינו שסיווג (החלטה בינרית) באמצעות רגרסיה לוגיסטית בודדת (=נוירון בודד) היא בעייתית במקרים המסובכים בהם ערכי המאפיינים של ה-classes השונים מפוזרים זה בתוך זה ולא נותנת תוצאות טובות. וזו המוטיבציה לפתור את המקרים המסובכים הללו באמצעות רשת נוירונים.

רשת נוירונים יכולה להפיק קו/משטח/מרחב הפרדה מורכבים (בעלי פונקציה אוניברסלית כלשהי) לעומת נוירון (מסווג) בודד שמפריד בין הסיווגים רק באמצעות ישר/מישור/מרחב ליניאריים. למעשה, רשת נוירונים מספיק עמוקה יכולה להגיע לאחוז הצלחה של קרוב מאוד ל-100% על סט נתוני אימון, אבל זה ממש לא מבטיח הצלחה של דומה גם על נתון אמת!!! ויותר מזה, הפתרון עלול להיות פחות טוב מפתרון אופטימלי יותר שנותן אחוז הצלחה נמוך יותר על סט הנתונים אבל ייתן אחוז הצלחה גבוה יותר על נתוני אמת – הסיבה לכך היא שהרשת למעשה "תפרה" פתרון ספציפי שמתאים לסט הנתונים שקיבלה בלי להשאיר "אזורי משחק" לנתונים שמתנהגים בצורה קצת שונה.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

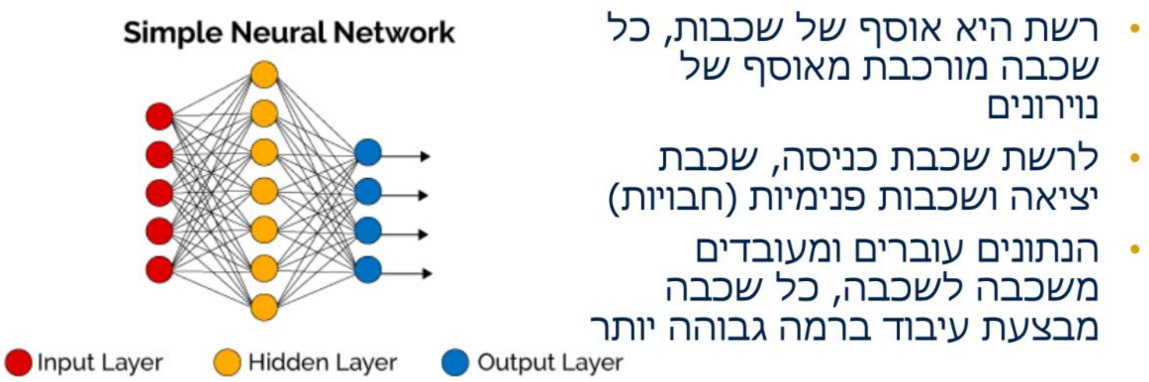

שכבת קלט (Input Layer) – מאפיינים. לדוגמא: אורך ורוחב של עלים ב-dataset של הפרחים. מסת גוף, אורך מקור, מין בפינגווינים.

שכבת פלט (Output Layer) – נתחיל את הלימוד ברשתות עם פלט מסווג בינרי (=נוירון בודד בשכבת הפלט).

שכבות ביניים (Hidden Layer) – שכבה אחת ברשת רדודה ויותר משכבה אחת ברשת עמוקה.

נוירון

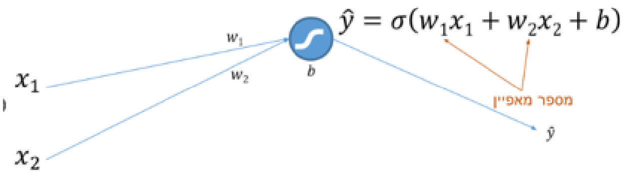

כל נוירון בשכבות הביניים הוא כמו רגרסיה לוגיסטית – יש לו קלטים, משקולות, ופונקציית אקטיבציה. פונקציית האקטיבציה היחידה שלמדנו עד כה היא סיגמואיד, אבל יש סוגים נוספים שנלמד בהמשך.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

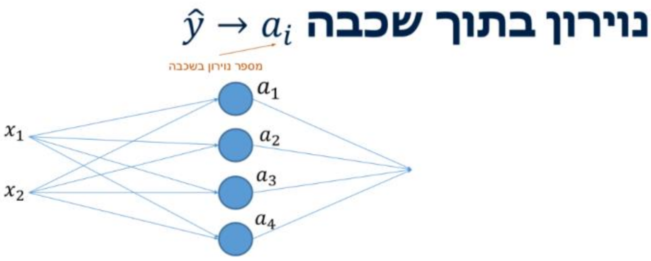

שיטת המספור של רשת נוירונים: את המוצא ($\hat{y}$) של הנוירון נסמן ב-a ואת מקומו בשכבה נסמן ב-i ולכן המוצא של הנוירון ה-i יסומן כ-a_i. והחותך של הנוירון הזה יסומן כ-b_i.

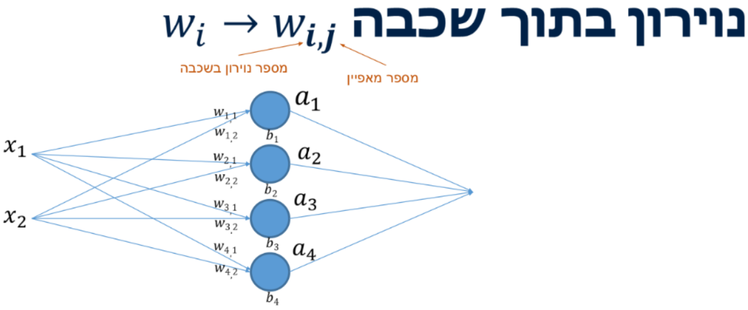

את מספרו של המאפיין בכניסה לנוירון נסמן ב-j ולכן המקדם של מאפיין זה בנוירון במקום ה-i יסומן כ-$w_{i,j}$.

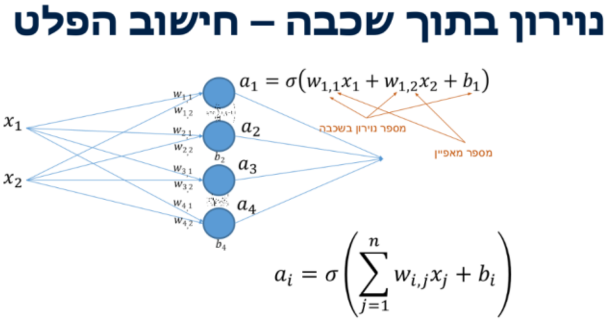

לפי שיטת הסימון שתוארה לעיל, הנוסחה לחישוב הפלט של נוירון בתוך שכבה היא $a_i = \sigma(\sum_{j=1}^{n} w_{i,j} * x_j + b_i)$ כאשר n היא כמות המאפיינים בכניסה לנוירון שזה למעשה מספר הנוירונים בשכבה הקודמת.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

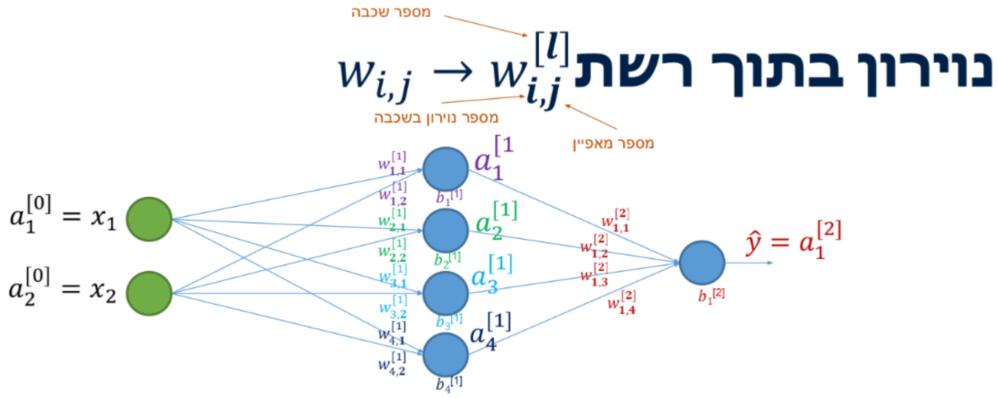

על מנת להתייחס לנוירון בתוך רשת בעלת יותר משכבת ביניים אחת, מוסיפים בסוגריים מרובעים מעל לסימונים של הנוירון את מספר השכבה $[l]$, כאשר שכבת הקלט מסומנת כ-$l = 0$.

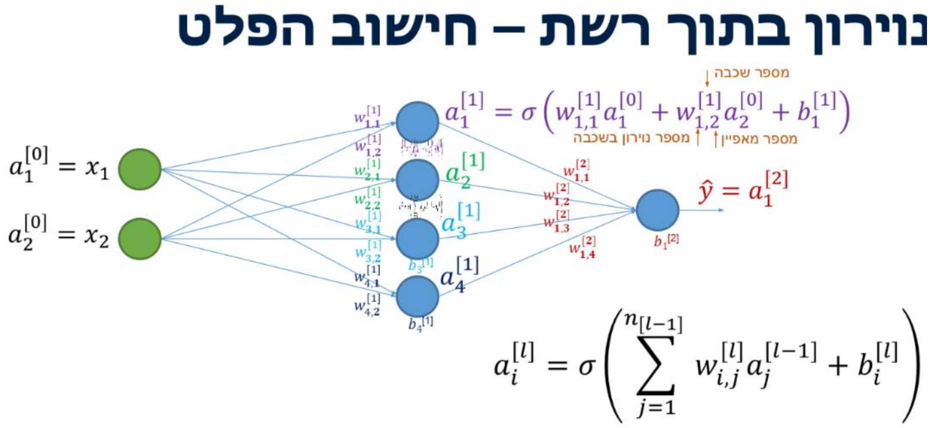

ולכן, הנוסחה לחישוב הפלט של נוירון בתוך שכבה l היא:

$$a_i^{[l]} = \sigma\left(\sum_{j=1}^{n_{[l-1]}} w_{i,j}^{[l]} * a_j^{[l-1]} + b_i^{[l]}\right)$$

כאשר n היא כמות הנוירונים בשכבה. הביטוי $n_{[l-1]}$ שרושמים כאן הוא למעשה כמות המאפיינים בכניסה לנוירון בשכבה l. שימו לב, הביטוי הזה נכון לשכבה 1 ומעלה ולא נכון לשכבה 0 שאין לה כניסות ולכן אין לה משקלות.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

חישוב מוצא הרשת

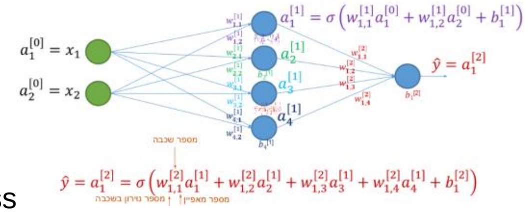

ss

תרגיל חישוב הפלט $a_1^{[2]}$:

$$a_1^{[2]} = \sigma\left(\sum_{j=1}^{n_{[1]}} w_{1,j}^{[2]} * a_j^{[1]} + b_1^{[2]}\right) = \sigma\left(\sum_{j=1}^{4} w_{1,j}^{[2]} * a_j^{[1]} + b_1^{[2]}\right) = \sigma\left(w_{1,1}^{[2]} * a_1^{[1]} + w_{1,2}^{[2]} * a_2^{[1]} + w_{1,3}^{[2]} * a_3^{[1]} + w_{1,4}^{[2]} * a_4^{[1]} + b_1^{[2]}\right)$$

הפרדת תפקידים בנוירון – חלק לינארי ואקטיבציה

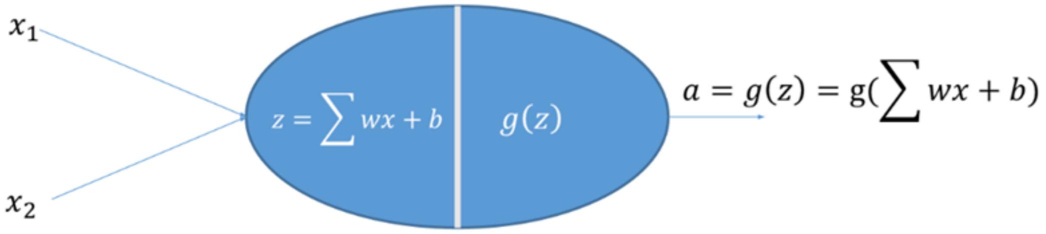

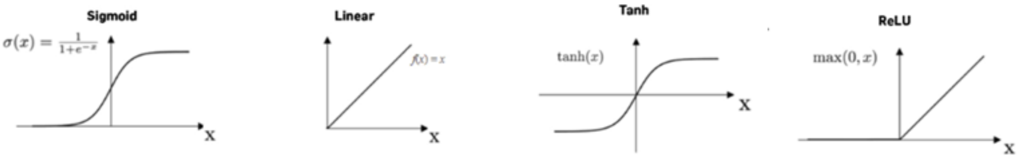

עד כה למדנו לבצע את האקטיבציה באמצעות פונקציית סיגמואיד שהיא מאוד שימושית בשכבת המוצא ובמיוחד בבעיות של סיווג לשני classes. אבל, קיימות פונקציות אקטיבציה נוספות רבות ובשקף ניתן לראות 4 דוגמאות מהן.

הפונקציה הכי שימושית היא Relu (Rectified Linear Unit).

- מאוד קלה לחישוב (max(0,x)).
- הנגזרת מאוד פשוטה – 0 עבור x שלילי ו-1 עבור x חיובי.

פונקציית linear היא למעשה "אין אקטיבציה". שימושית בבעיות רגרסיה בהן נדרש לחזות במוצא כל ערך שהוא (ולא לסווג) שיכול להיות גם חיובי וגם שלילי.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

הדרישות מפונקציית אקטיבציה:

- חייבת להיות לא לינארית כי אם היא לינארית ניתן להוכיח שהיא מיותרת וניתן לאחדה עם שכבה סמוכה שגם היא לינארית.
- גזירה עבור כל x. הדרישה הזו לכאורה לא מתקיימת ב-Relu אבל ניתן להחליט שרירותית שהנגזרת עבור x=0 היא 0. תשובה נוספת היא שהסיכוי ש-x יהיה בדיוק 0 בתהליך למידת מכונה הוא אפסי עקב פעולות ה-float המתבצעות בתהליך.

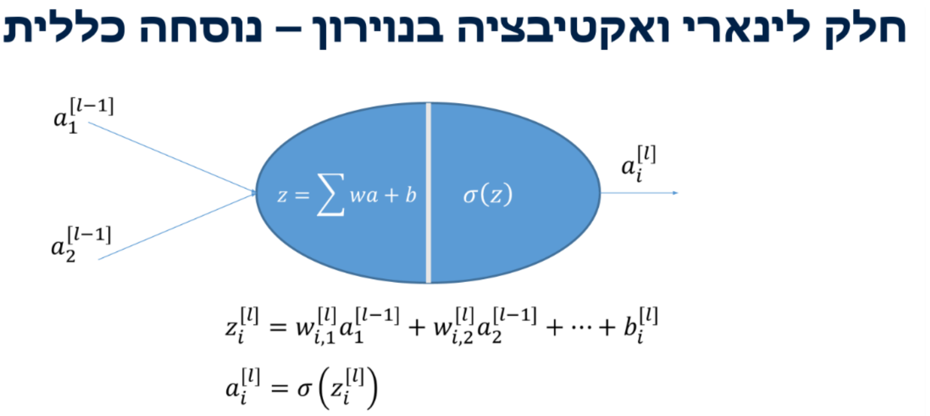

בתמונה רשום סיגמואיד באקטיבציה, אבל, כאמור לעיל, יכולה להיות גם פונקציית אקטיבציה אחרת.

Sklearn MLPClassifier

MLPClassifier (**M**ulti-**L**ayer **P**erceptron) מבוסס על רגרסיה לינארית ורגרסיה לוגיסטית של Sklearn .

בתרגיל שתבצעו בהמשך על סט הנתונים של הפינגווינים נדרש לחזות גם משתנה בדיד Dual Class (sex) וגם משתנה בדיד שהוא Multi Class (species ו-island).

הורידו ל-drive את מחברת ה-Dual Class ותנו לה את השם/קישור Neural network sklearn dual class_Iris_didi.ipynb.

במקטע ייבוא הספריות נוספה השורה:

```
from sklearn.neural_network import MLPClassifier
```

- כפי שראיתם בסוף הפרק הקודם, לא ניתן היה לחזות את "האם versicolor" באמצעות רגרסיה לוגיסטית בודדת. כשמבצעים זאת בשתי רגרסיות הייתם צריכים "להנדס" את התהליך ולשאול איזה חיתוכים נדרשים לבצע? בעבודה עם רשת הנוירונים החיזוי מבוצע בהצלחה באופן אוטומטי.
- מקטע קביעת ה-Hyper Parameters עבור רשת רדודה (רשת עם שכבת hidden אחת):
  - hidden_layer_size = 15 #must be large enough

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

- learning_rate = 0.1
- epochs = 20000

ה-sklearn רגיש למספר נוירונים קטן ולכן עלול שלא לעבוד עבור hidden_layer_size נמוך מידי.

במידה ורוצים לעבוד עם רשת עמוקה (יותר משכבת ביניים אחת) יש להכניס בהשמה hidden_layer_size רשימה של מספר הנוירונים בכל אחת משכבות הביניים. למשל עבור, שתי שכבות ביניים עם 15 נוירונים בראשונה ו-4 בשנייה יש לרשום hidden_layer_size=[15,4] כפי שתראו בהמשך המחברת.

ה-epochs הוא כמות המעברים שרוצים לבצע על ה-Data Set.

- מספר השכבות ברשת (כולל שכבות הכניסה והיציאה):

```
[7] mlp.n_layers_

3
```

- מטריצות ה-W:

```
[8] W1 = mlp.coefs_[0]
    W2 = mlp.coefs_[1]
    print(W1.shape, W2.shape)

(2, 15) (15, 1)
```

W1 היא מטריצת המקדמים בין שכבת הכניסה לשכבת הביניים ו-W2 היא מטריצת המקדמים בין שכבת הביניים לשכבת היציאה.

ה-(2,15) הם הממדים של W1 שהיא מטריצה של 2 שורות עם 15 עמודות והיא מכילה את המקדמים בין 2 "הנוירונים" (=המאפיינים 'PetalLengthCm','PetalWidthCm') שבשכבת הכניסה ו-15 בנוירונים שבשכבת הביניים.

ה-(15,1) הם הממדים של W2 שהיא מטריצה של 15 שורות עם עמודה אחת והיא מכילה את המקדמים בין 15 הנוירונים שבשכבת הביניים והנוירון הבודד ("האם versicolor") שבשכבת היציאה.

- וקטורי ה-b:

```
[9] b1 = mlp.intercepts_[0]
    b2 = mlp.intercepts_[1]
    print(b1.shape, b2.shape)

(15,) (1,)
```


כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

b1 הוא ווקטור החותכים של 15 הנוירונים שבשכבת הביניים ו-b2 הוא "ווקטור" (בעל אורך 1 = מספר) החותך של הנוירון הבודד שבשכבת היציאה.

- חישוב accuracy ומטריצת הבלבול:

```
[10] mlp.score(X,y) #compute accuracy
```

```
0.96
```

```
[11] ConfusionMatrixDisplay.from_estimator(mlp, X, y);
```

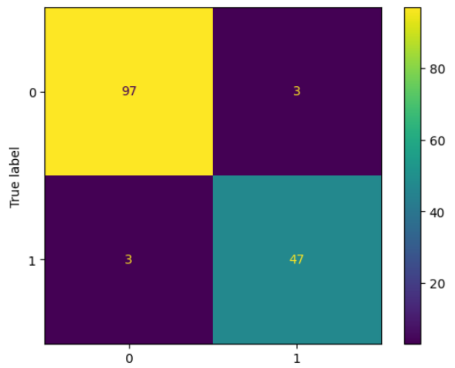

החישוב מתבצע ע"י הפעלת המשקלים על סט נתוני האימון והשוואה לתגיות הנתונות.

- מקטע קביעת ה-Hyper Parameters עבור רשת עמוקה (רשת עם 2 שכבות hidden):

- hidden_layer_size = [15,20] #must be large enough
- learning_rate = 0.1
- epochs = 20000

- וזה נותן רשת של 4 שכבות (כולל שכבות הכניסה והיציאה) עם 3 מטריצות מקדמים הקושרים בין 4 השכבות ו-3 ווקטורים של החותכים של הנוירונים בשכבות הביניים ושכבת היציאה:

```
[15] W1 = mlp.coefs_[0]
     W2 = mlp.coefs_[1]
     W3 = mlp.coefs_[2]
     print(W1.shape, W2.shape, W3.shape)
```

```
(2, 15) (15, 20) (20, 1)
```

```
[16] b1 = mlp.intercepts_[0]
     b2 = mlp.intercepts_[1]
     b3 = mlp.intercepts_[2]
     print(b1.shape, b2.shape, b3.shape)
```

```
(15,) (20,) (1,)
```


כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

- ניתן לראות שבמקרה הזה העמקת הרשת לא שיפרה את הדיוק ולא שינתה את מטריצת הבלבול:

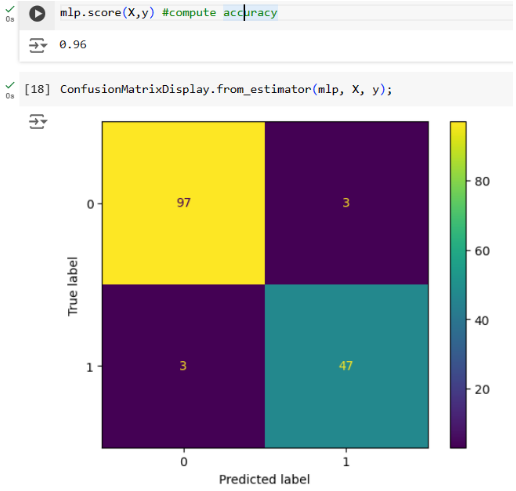

הורידו ל-drive את מחברת ה-Multi Class ותנו לה את השם/קישור [Neural network sklearn multi class_Iris_didi.ipynb].
המחברת הזו דומה מאוד לזו שלמדתם ב-Dual-Class עם השינויים הבאים:

- במקום להגדיר את ה-y כסיווג בינרי של "האם 'versicolor" :

y=1*(df['Species']=='Iris-versicolor').to_numpy()

הגדרתם את ה-y כטקסט של סיווג של אחד מתוך כל (3) הסיווגים האפשריים:

y=df['Species'].to_numpy()

- ולכן, גרף הפיזור של המאפיינים נצבע עכשיו ב-3 צבעים (לעומת 2 צבעים ב-Dual-Class):

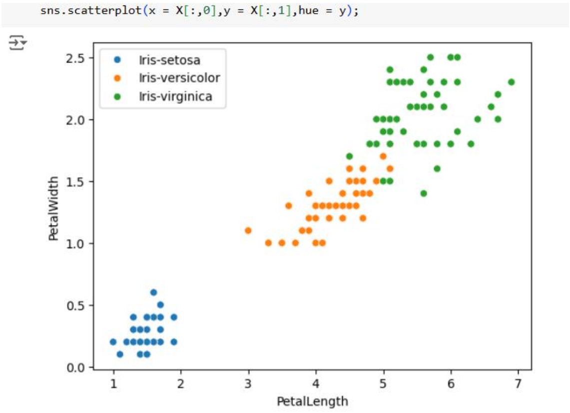

- ממדי מטריצה W2 משתנים מ-(15,1) ל-(15,3) וממד הווקטור b2 משתנים מ-(1,) ל-(3,).

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
[8] W1 = mlp.coefs_[0]
    W2 = mlp.coefs_[1]
    print(W1.shape, W2.shape)

(2, 15) (15, 3)
```

```
[9] b1 = mlp.intercepts_[0]
    b2 = mlp.intercepts_[1]
    print(b1.shape, b2.shape)

(15,) (3,)
```

- אחוזי הדיוק נשארו כמו ב-Dual, אבל המשימה הייתה מורכבת יותר (סיווג של 3 במקום של 2) ומטריצת הבלבול היא 3x3 (לעומת 2x2 ב-Dual):

```
[92] mlp.score(X,y) #compute accuracy

0.96

[93] ConfusionMatrixDisplay.from_estimator(mlp, X, y);
```

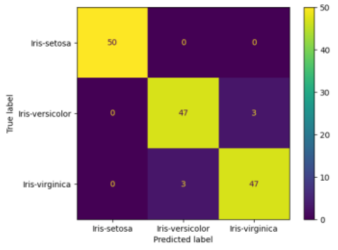

- העמקת הרשת (הוספת שכבה פנימית נוספת של 10 נוירונים) לא שיפרה את הדיוק ולא שינתה את מטריצת הבלבול.

תרגיל – MLP Classifier

טענו את המחברת Penguin Dataset, השתמשו ב-MLPClassifier:

א. נסו לחזות את אחד המשתנים הבדידים (species, island, sex) על פי משתני ה-float. חשבו מדד accuracy. ציירו מטריצת הבלבול.

ב. בצעו את סעיף א' על משנה בדיד נוסף.

הורידו ל-drive את מחברת ה-Penguin Dataset ולתת לה את השם/קישור Penguin dataset_didi.ipynb.

- ההוראה df.dropna(inplace=True מוחקת מה-dataset את כל השורות בהן יש ערך ריק באיזושהי עמודה.

הוסיפו הוראות ()df.info ו-()df.head לפני ואחרי ה-df.dropna על מנת לראות את השינוי.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

מחיקה כזו גורמת לאיבוד המידע הנתון באותה שורה בשאר העמודות/מאפיינים ולכן בפועל לא מקובל לבצע מחיקה גורפת כזו אלא להשלים את החסר עם איזשהו ערך (ממוצע העמודה/ערך קצה/...) אבל היות ואנו לא עוסקים כאן בטיפול ב-dataset אלא ברשת עמוקה, הכי פשוט הוא למחוק את כל השורה.

- ההוראה ;sns.countplot(data=df,x='species') מציגה מספר שורות/דוגמאות יש מכל סוג של פינגווין. אפשר לשנות על מנת לספור כמות כל מין או כל אי.
- ההוראה ;sns.pairplot(data=df.drop(['island','species'],axis=1), hue='sex') מציגה את מטריצת גרפי הפיזור של צירופי זוגות של כל עמודות המאפיינים המספריים תוך צביעה של הנקודות לפי אחת העמודות של מאפיין סיווגי (sex) ו-drop של כל שאר העמודות המסווגות (island ו-species). ניתן לראות כאן שרגרסיה על הצירוף של bill_depth עם body_mass קל להפרדה וייתן סיווג ברמת דיוק גבוהה.

באלכסון המטריצה מופיעות הסטוגרמות של כמויות ה-sex (זכר/נקבה) על התחום של המאפיין המספרי וניתן לראות שכל ההסטוגרמות די חופפות ולכן יהיה שקשה לחזות את ה-sex לפי מאפיין אחד בלבד.

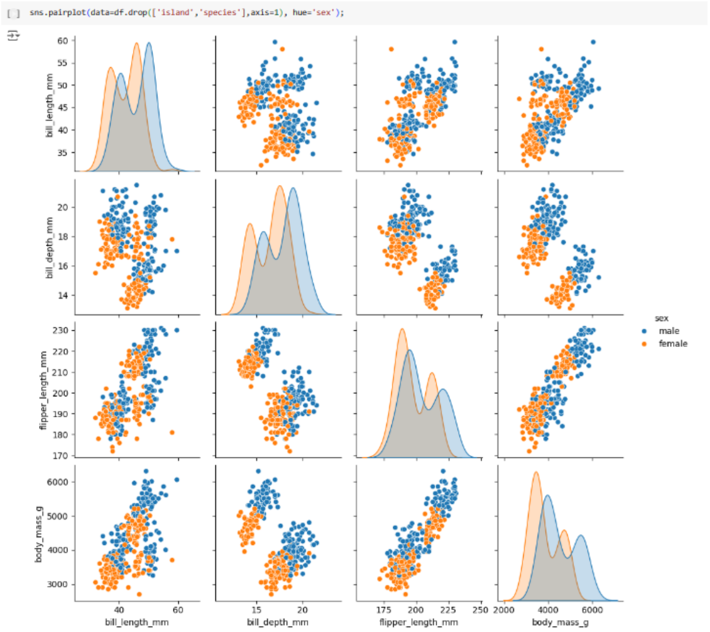

להוסיף הוראה בה מחליפים את sex ב-species:

```
sns.pairplot(data=df.drop(['island','sex'],axis=1), hue='species');
```

מקבלים את מטריצת גרפי הפיזור של צירופי זוגות של כל עמודות המאפיינים המספריים תוך צביעה של הנקודות לפי סוג הפינגווין והסטוגרמות של כמויות כל אחד מ-3 הסוגים על התחום של המאפיין המספרי. מגרפי

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

הפיזור ניתן לראות שניתן לבצע חיזוי Gento בסבירות גבוהה מאוד לפי מספר זוגות של מאפיינים ולעומת זאת קשה לחזות Chinstrap לפי שני מאפיינים.
ניתן לראות שבחלק מההסטוגרמות יש חפיפה מעטה (למשל Gentoo לפי flipper_length) ולכן יהיה ניתן לחזות את סוג הפינגווין בהסתברות טובה גם לפי מאפיין אחד בלבד.

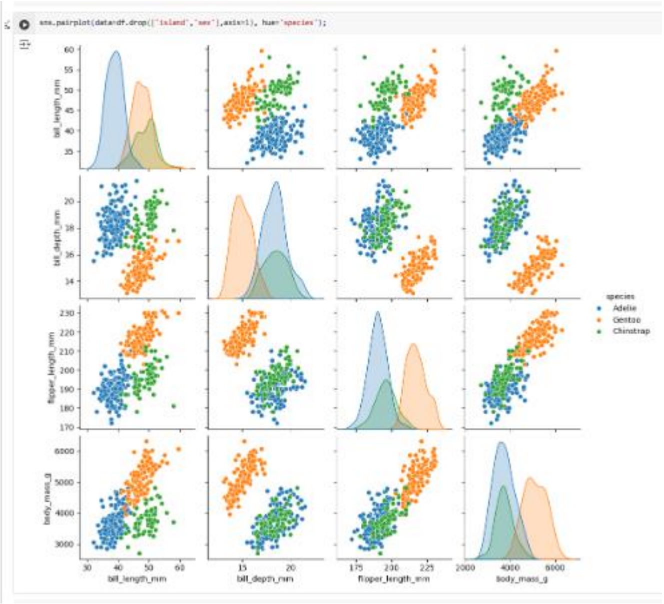

- הגדירו מטריצת הכניסות X (עם כל המאפיינים המספריים) ווקטור היציאה y (species) עבור ה-train :

```
[ ] X=df[['bill_length_mm', 'bill_depth_mm','flipper_length_mm', 'body_mass_g']].to_numpy()
    y= df['species'].to_numpy()
    print ("X.shape=",X.shape)
    print ("y.shape=",y.shape)
```

```
X.shape= (333, 4)
y.shape= (333,)
```

```
X
```

```
array([[  39.1,   18.7,  181. , 3750. ],
       [  39.5,   17.4,  186. , 3800. ],
       [  40.3,   18. ,  195. , 3250. ],
       ...,
       [  49.6,   18.2,  193. , 3775. ],
       [  50.8,   19. ,  210. , 4100. ],
       [  50.2,   18.7,  198. , 3775. ]])
```


משרד החינוך
המזכירות הפדגוגית
אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ
המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

- נרמלו ערכים לתחום 0-1 במטריצת הכניסה:

Using MinMaxScaler

```
[ ] print('Max: ', X.max())
    print('Min: ', X.min())
    scaler = MinMaxScaler()
    X=scaler.fit_transform(X)
    print('Max: ', X.max())
    print('Min: ', X.min())
```

```
Max:  6300.0
Min:  13.1
Max:  1.0
Min:  0.0
```

```
[ ] X
```

```
array([[0.25454545, 0.66666667, 0.15254237, 0.29166667],
       [0.26909091, 0.51190476, 0.23728814, 0.30555556],
       [0.29818182, 0.58333333, 0.38983051, 0.15277778],
       ...,
       [0.63636364, 0.60714286, 0.3559322 , 0.29861111],
       [0.68      , 0.70238095, 0.6440678 , 0.38888889],
       [0.65818182, 0.66666667, 0.44067797, 0.29861111]])
```

הפעלת הרשת על dataset בהם המאפיינים המספריים השונים הם בעלי סדר גודל שונה זה מזה עלולה לגרום לכל מיני תופעות לא טובות (למשל, תחזיות שונות בהרצות חוזרות על אותו dataset של הפינגווינים עקב בסקלה השונה ב-3 סדרי גודל של המשקל בגרמים לעומת המידות בס"מ בודדים) בהן העמודה בעלת הערכים הגבוהים משפיעה על החיזוי באופן הרבה יותר גבוה מאשר "מגיע לה" וזה קורה במיוחד ברשתות KNN (שלא נתייחס אליהן במסמך זה).

למשל: זה לא נכון שמשקל של 3500 גרם ישפיע יותר מאשר משקל של 3.5 ק"ג.

סיבה נוספת לצורך בנרמול: בגלל הצורה שהרשת עובדת, היא יותר יציבה ו"אוהבת" מבחינה מתמטית מספרים קטנים ומספרים גדולים נוטים להתנפח ולגרום ל-exploding gradient .

ה-Scaler ממפה את הערכים של כל העמודות לתחום 0-1. לכל עמודה יש פרמטרי מיפוי משלה אותם יש לשמור ולהפעיל גם על ה-test dataset וגם על ה-dataset האמיתיים בשלב המבצעי.

<u>תרגיל:</u>

צרו העתק של המחברת Penguin dataset_didi.ipynb עליה עבדתם קודם וקראו לה בשם/קישור [MLP Classifier_Targil1.ipynb] וכאן יש את פתרון התרגיל.

ה-X וה-y שהגדרתם קודם מתאים לחיזוי species לפי כל 4 המאפיינים. את תהליך ה-train מבצעים בצורה דומה לזו שביצעתם במחברת Neural network sklearn multi class_Iris_didi.ipynb. בהרצה עם ההיפר פרמטרים:

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
hidden_layer_size = 15 #must be large enough
learning_rate = 0.1
epochs = 20000
```

חיזוי של 100% ובריצות חוזרות התנדנדה התוצאה בין 99.7% עם שגיאה אחת של חיזוי Adelie כ-Chinstrap לבין 100%.

בהורדה ל-10 = hidden_layer_size התקבל חיזוי של 99.7% עם שגיאה אחת של חיזוי Adelie כ-Chinstrap אבל בהרצות חוזרות התוצאה חזרה ל-100%. בהורדה ל-5 = hidden_layer_size התקבל חיזוי של 99.7% עם שגיאה אחת של חיזוי Adelie כ-Chinstrap ובריצות חוזרות הדיוק ירד ל-95.8% (14 שגיאות) עלה ל-100%, ירד ל-96.1% (13 שגיאות)....

אם מחזירים ל-10 = hidden_layer_size ומציבים learning_rate = 0.2 מקבלים 97% ובהרצות חוזרות 100%.
אם מורידים ל-10000 = epochs , מתקבל חיזוי של 99.7% עם שגיאה אחת של חיזוי Chinstrap כ-Adelei ובהרצה חוזרות התוצאה נעה בין ל-98.8% ל-99.7% ו-100%.

לפי הגרפים של פיזור ה-dataset בתחילת המחברת, ניתן לעבור לבעיה מאתגרת יותר של חיזוי species לפי כל 2 המאפיינים bill_depth. ו-body_mass. בהרצה עם ההיפר פרמטרים:

```
hidden_layer_size = 15 #must be large enough
learning_rate = 0.1
epochs = 20000
```

מהאיור הבא ניתן לראות שיש כשלון מוחלט בחיזוי ה-chinstrap

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

בכדי לשפר את המודל ניתן להציב ערכים שונים ולבדוק אם חל שיפור בביצועים, לדוגמה:

```
hidden_layer_size = 1000 #must be large enough
learning_rate = 0.01
epochs = 100000
```

(תוצאה: לא חל שיפור בביצועים של חיזוי ה-chinstrap)

שיפור באמצעות רשת עמוקה:

```
hidden_layer_sizes = [150,100,100] #must be large enough
learning_rate = 0.05
epochs = 50000
```

(התוצאה – לא חל שיפור בביצועים של חיזוי ה-chinstrap).

לפי הגרפים של פיזור ה-dataset בתחילת המחברת, ובמעבר לבעיה פחות מאתגרת יותר של חיזוי sex לפי 2 המאפיינים bill_depth. ו-body_mass.

בהרצה עם ההיפר פרמטרים:

```
hidden_layer_size = 15 #must be large enough
learning_rate = 0.1
epochs = 20000
```


משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה כשמדע וחינוך נפגשים
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

מקבלים:

```
[678] mlp.score(X,y) #compute accuracy
0.9069069069069069
```

```
[679] ConfusionMatrixDisplay.from_estimator(mlp, X, y);
```

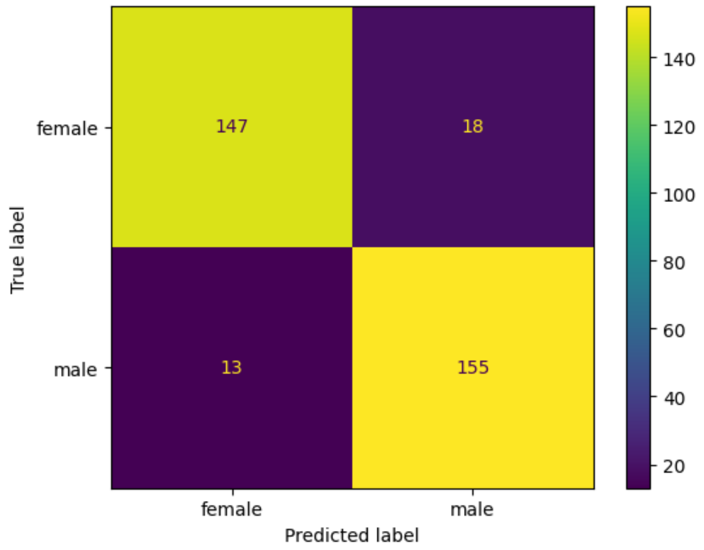

הפרדת ה-Dataset ל-Train ו-Test

עד כה בצעתם אימון על סט דוגמאות ולאחר מכן בדיקה על אותו סט. צורה בדיקה כזו אינה באמת חוזה ביצועים על סט חדש שלא השתתף בתהליך הבדיקה.

ולכן, נהוג לחלק את כמות השורות/דוגמאות של ה-dataset הנתון לשני datasets נפרדים, train ו-test. למשל: 90% מהשורות יהיו ל-train ו-10% ל-test. את הנרמול (Scale) רצוי לבצע לאחר החלוקה ובכל מקרה, יש לבצע את הנרמול של ה-test עם אותם פרמטרים של ה-train.

לצורך ביצוע החלוקה קיימת פונקציה בשם train_test_split.

הורידו ל-drive שלכם את המחברת sklearn multi class with train-test split שעושה Neural network שימוש בפונקציה train_test_split ותנו לה את השם/קישור sklearn multi class with train-test split_Didi.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```python
X=df[['SepalLengthCm', 'SepalWidthCm', 'PetalLengthCm', 'PetalWidthCm']].to_numpy()
y=df['Species'].to_numpy()
print ("X.shape=",X.shape)
print ("y.shape=",y.shape)
```

```
X.shape= (150, 4)
y.shape= (150,)
```

לאחר שמגדירים את ה-X וה-y של ה-dataset, מפעילים את הוראת הפיצול באופן הבא:

```python
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.20, random_state=42)
print(X_train.shape, X_test.shape)
print(y_train.shape, y_test.shape)
```

```
(120, 4) (30, 4)
(120,) (30,)
```

- ה-X,y מפוצלים ל-X_train,y_train ו-X_test,y_test.
- גודל ה-test הוא 20% (0.2) מה-X,y המקורי (ולכן, גודל ה-train הוא 80% (0.8) מה-X,y המקורי).
- בהדפסות ה-shape רואים שהגודל המקורי של הוא 150 וזה פוצל ל-120 (80%) ל-train ו-30 (20%) ל-test.
- בחירת השורות בחלוקה היא אקראית ותיתן בסופו של דבר, בכל הפעלה של המזהה, תוצאות סיווג שונות במקצת. במידה ורוצים לקבוע חלוקה זהה (ותוצאת סיווג זהה) בכל הפעלה, יש להוסיף את הפרמטר =random_state ולתת לו ערך שלם כלשהו שיקבע את צורת בחירת השורות.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

ניתן להגדיר בהוראה את אותה החלוקה בצורה הפוכה (train_test_split(X, y, train_size=0.80, random_state=42)

- את הוראת ה-fit (ביצוע האמון) יש להפעיל על X_train,y_train ואת ה-score וה-ConfusionMatrix על X_test,y_test:

```
mlp.fit(X_train,y_train) #fit on train data
```

```
MLPClassifier
MLPClassifier(hidden_layer_sizes=15, learning_rate_init=0.1, max_iter=20000)
```

```
[ ] mlp.score(X_test,y_test) #compute accuracy on test
```

```
0.9666666666666667
```

```
[ ] ConfusionMatrixDisplay.from_estimator(mlp, X_test, y_test); #on test
```

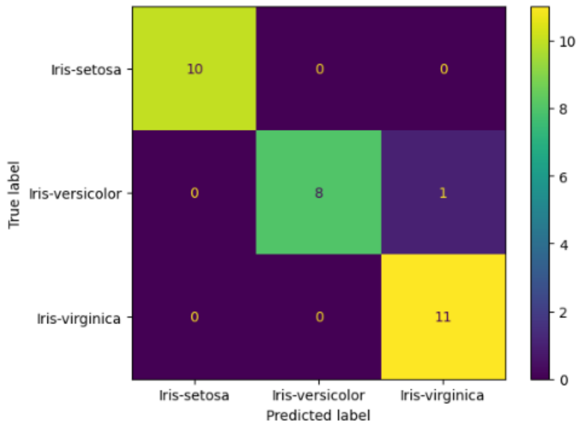

חלוקה ל-Train, Test – תרגיל

צרו עותק של המחברת MLP Classifier on Penguin dataset_Targil1 וקראו לה בשם/קישור:

[MLP Classifier on Penguin dataset_with split train-test_Targil2](#)

ובצעו את התרגיל הבא:
הוסיפו חלוקה ל-train, test
נסו להקטין ולהגדיל את ה-test_size
נסו לשנות את ה-random_state
נסו לשנות פרמטרים נוספים

עבור:

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק מרכז המורים הארצי למקצועות הטכנולוגיים
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
[9] X=df[['bill_depth_mm','body_mass_g']].to_numpy()
    y= df['sex'].to_numpy()
    print ("X.shape=",X.shape)
    print ("y.shape=",y.shape)

X.shape= (333, 2)
y.shape= (333,)
```

```
[27] X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.20, random_state=42)
     print(X_train.shape, X_test.shape)
     print(y_train.shape, y_test.shape)

(266, 2) (67, 2)
(266,) (67,)
```

```
[28] hidden_layer_size = 15 #must be large enough
     learning_rate = 0.1
     epochs = 20000
```

מקבלים את התוצאה של המצב ההתחלתי (אותם היפר פרמטרים של הרשת וללא חלוקה ל-train-test)

```
[36] mlp.score(X_test,y_test) #compute accuracy

0.8805970149253731

[37] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

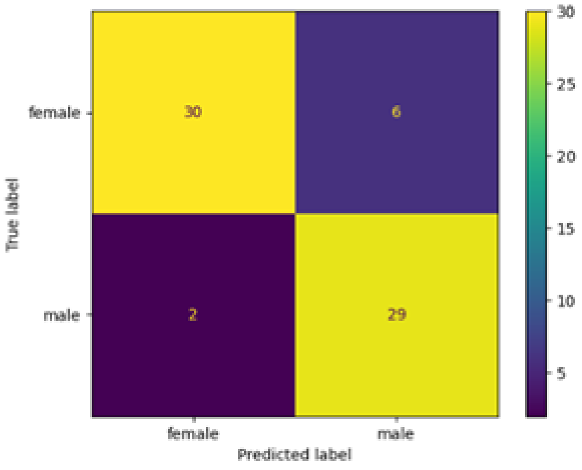

הייתה בחלוקה ל-train-test אחוז הדיוק ירד מ-90% ל-88%.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
mlp.score(X,y) #compute accuracy
0.9009009009009009
```

```
[56] ConfusionMatrixDisplay.from_estimator(mlp, X, y);
```

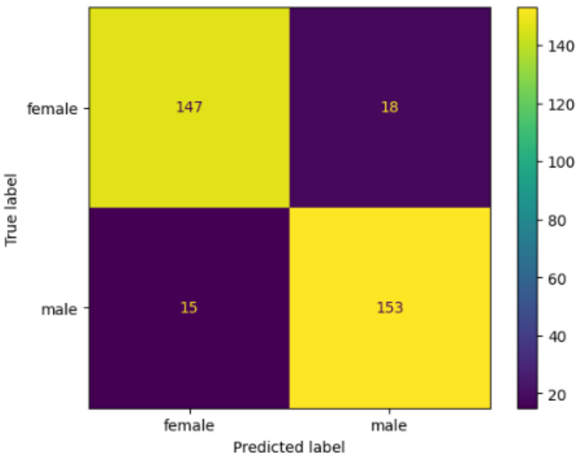

הגדלת ה-test_size מ-20% ל-30% נותנת : ירידה מ-88% ל-87%.

```
[79] mlp.score(X_test,y_test) #compute accuracy
0.87
```

```
[80] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

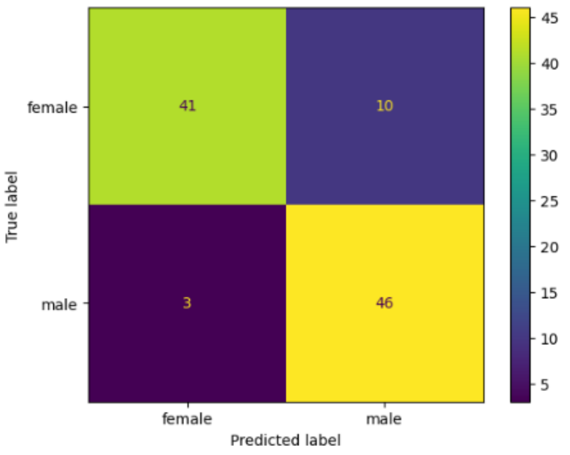

הקטנת ה-test_size מ-20% ל-10% נותנת עלייה מ-88% ל-91%.

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
[88] mlp.score(X_test,y_test) #compute accuracy
```

```
0.9117647058823529
```

```
[89] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

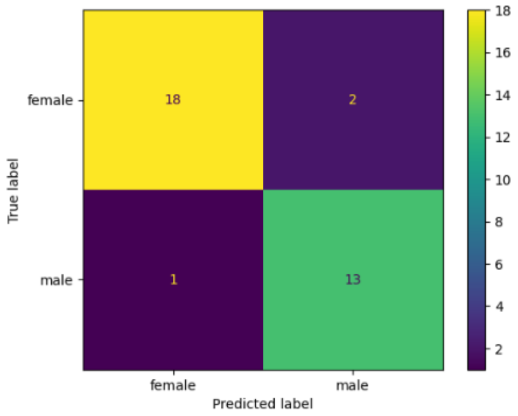

הקטנת ה-test_size מ-20% ל-5% נותנת עלייה מ-88% ל-100%.

```
[115] mlp.score(X_test,y_test) #compute accuracy
```

```
1.0
```

```
[116] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

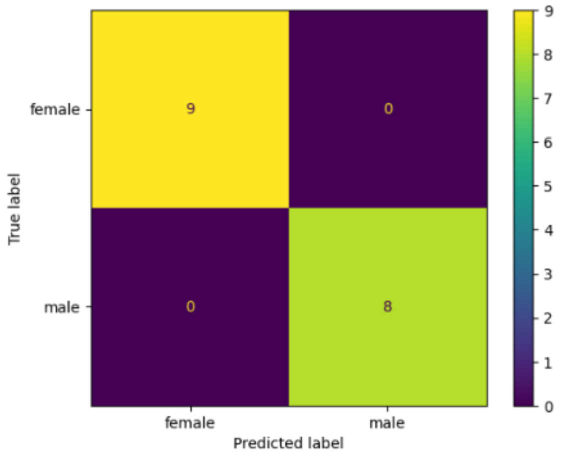

הקטנת ה-test_size מ-20% ל-3% נותנת גם כאן עלייה מ-88% ל-100%.

משרד החינוך
המזכירות הפדגוגית
אגף א' למדעים
מנהל החינוך הטכנולוגי
המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
מור-טק
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה
כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

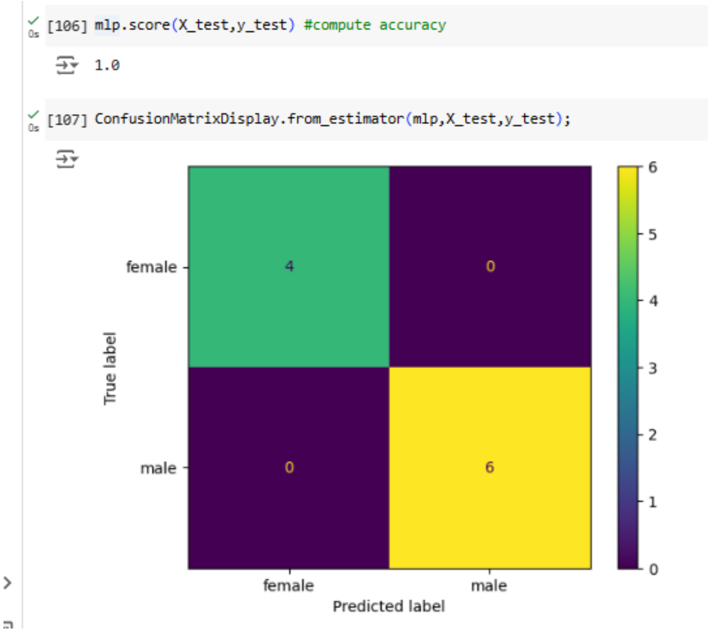

הקטנת ה-test_size מ-20% ל-1% נותנת גם כאן עלייה מ-88% ל-100%.

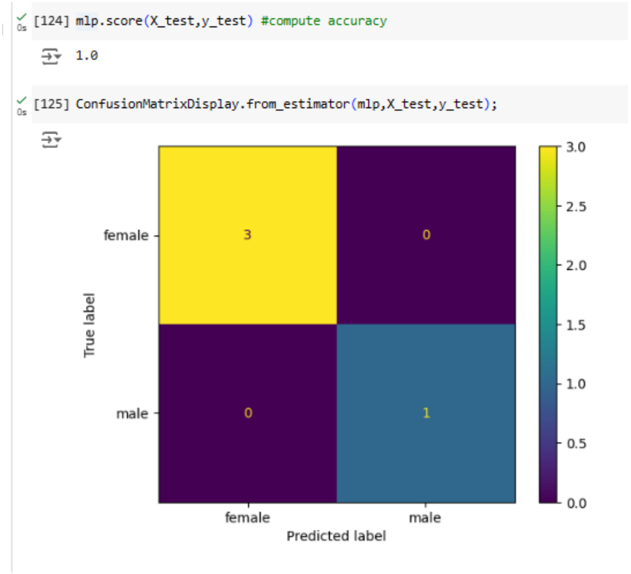

שינוי של ה-random_state מ-42 ל-3 עם המצב ההתחלתי של ההיפר פרמטרים גורם לעליה בביצועים עם תוצאות שונות בהרצות עוקבות:

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
[226] mlp.score(X_test,y_test) #compute accuracy
0.9104477611940298
```

```
[227] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

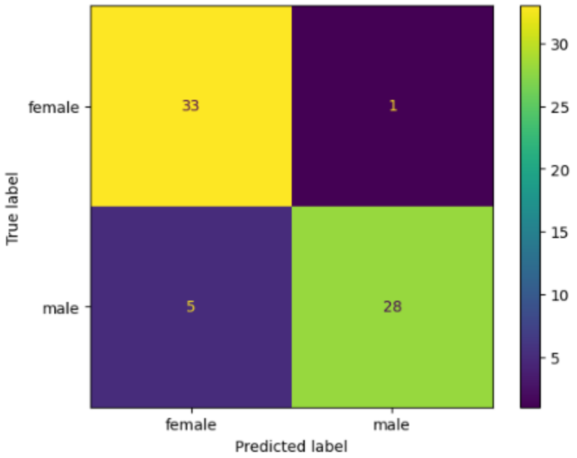


```
[234] mlp.score(X_test,y_test) #compute accuracy
0.9701492537313433
```

```
[235] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

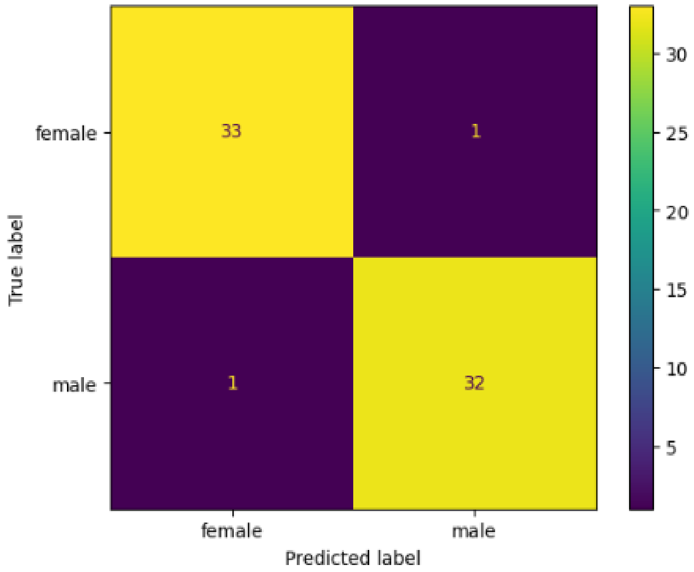

משרד החינוך המזכירות הפדגוגית אגף א' למדעים
מנהל החינוך הטכנולוגי
מל"מ המרכז הישראלי לחינוך מדעי טכנולוגי ע"ש עמוס דה-שליט
הטכניון מכון טכנולוגי לישראל
הפקולטה לחינוך למדע וטכנולוגיה

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
[242] mlp.score(X_test,y_test) #compute accuracy
```

```
0.9552238805970149
```

```
[243] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

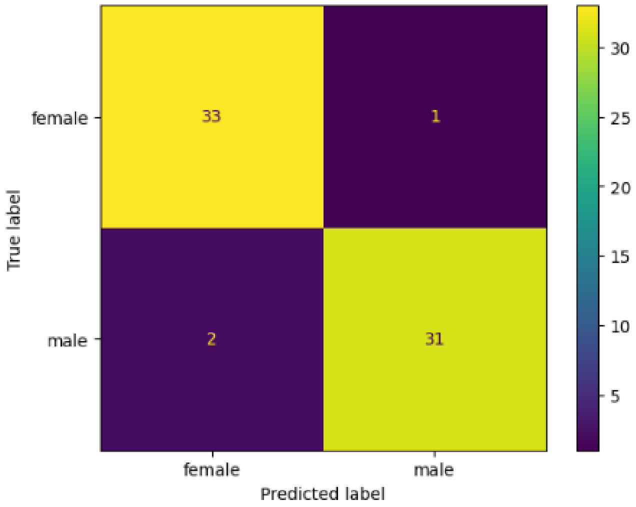

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך

```
[250] mlp.score(X_test,y_test) #compute accuracy
```

```
0.9402985074626866
```

```
[251] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

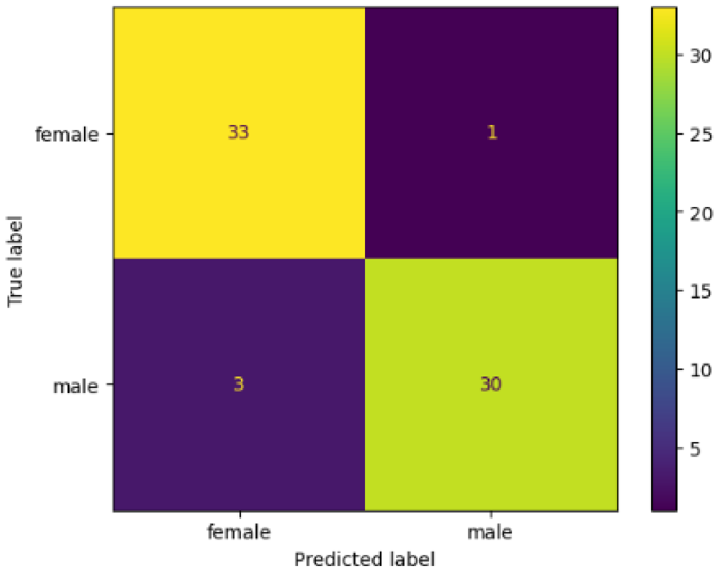


```
[258] mlp.score(X_test,y_test) #compute accuracy
```

```
0.9701492537313433
```

```
[259] ConfusionMatrixDisplay.from_estimator(mlp,X_test,y_test);
```

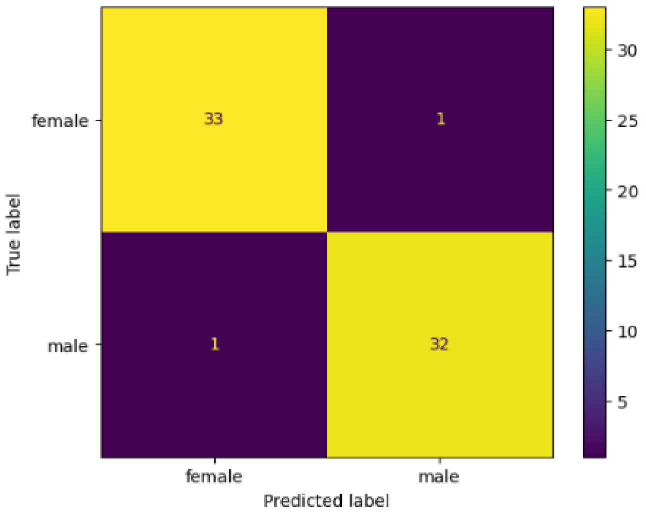

כל הזכויות שמורות למשרד החינוך, מרכז המורים הארצי למקצועות הטכנולוגיים, מור-טק
הפרויקט מבוצע על ידי מוסד הטכניון עפ"י מכרז 22/11.2020. הפרויקט מבוצע עבור המזכירות הפדגוגית, משרד החינוך