Вступ до Data Science. Знайомство з бібліотекою Numpy

Заняття 1

Python для Data Science

ПЛАН ЗАНЯТТЯ

- Знайомство
- Формулювання задач машинного навчання
- Основні види задач машинного навчання
- Фреймворк роботи над задачами Data Science
- Знайомство з бібліотекою Numpy, її призначення і застосування

MACHINE LEARNING VS TRADITIONAL PROGRAMMING

Traditional Programming

Developers write rules (program) that produce an output.

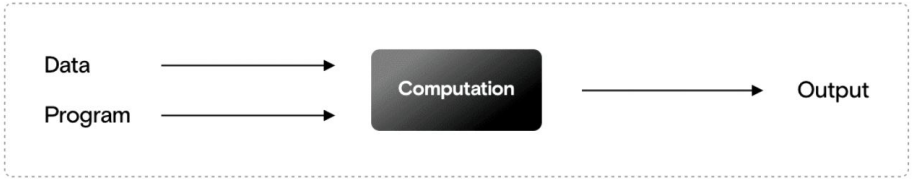

Machine Learning

Developers write a training algorithm, that finds rules, which produce the desired output.

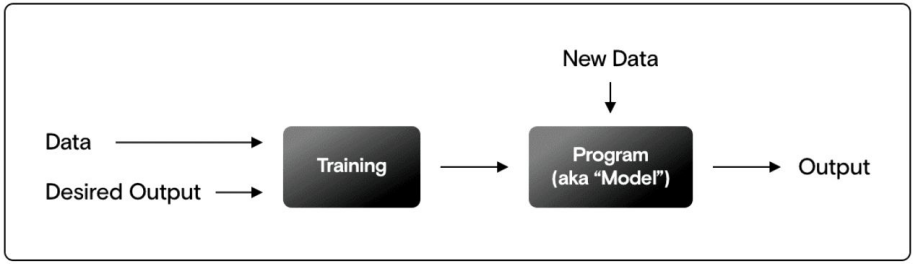

MACHINE LEARNING VS TRADITIONAL PROGRAMMING

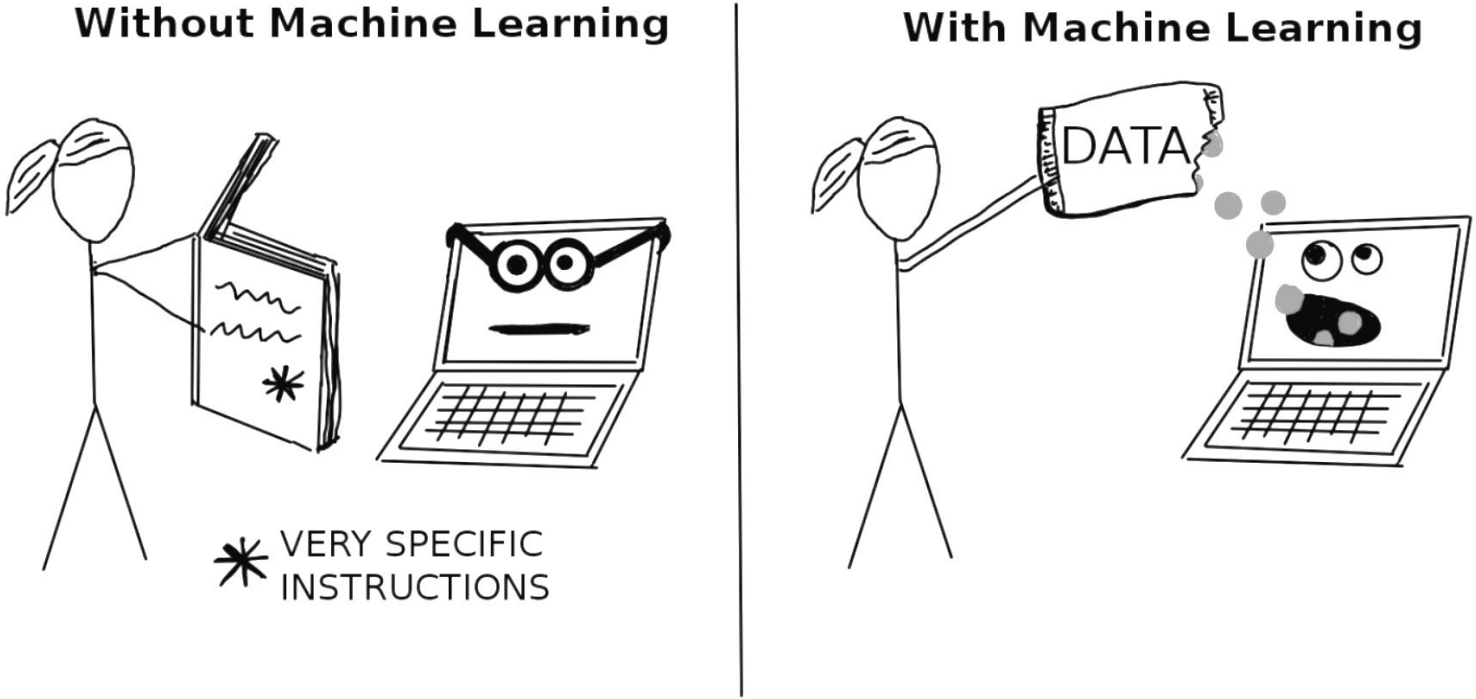

MACHINE LEARNING

EXAMPLES OF MACHINE LEARNING TASKS

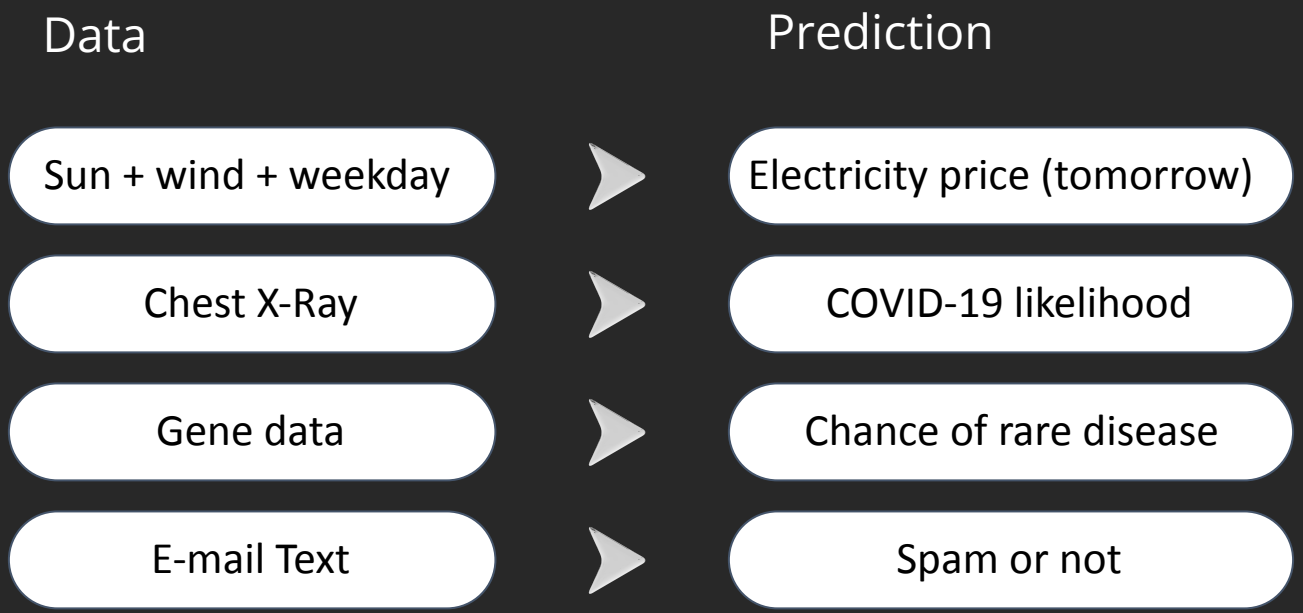

EXAMPLES OF MACHINE LEARNING TASKS

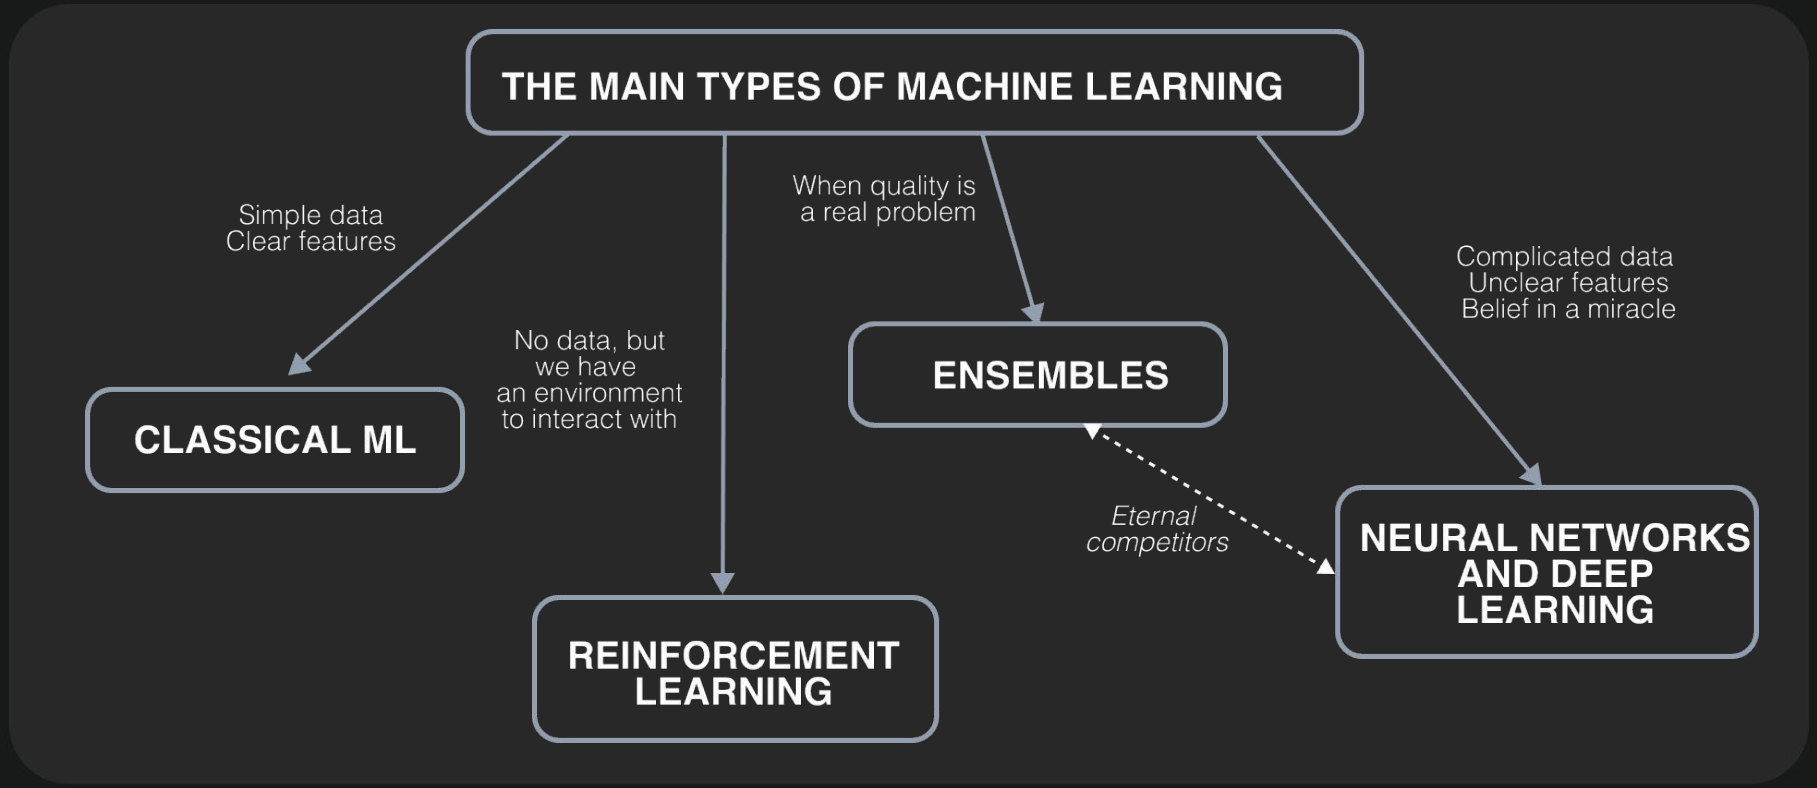

EXAMPLES OF MACHINE LEARNING TASKS

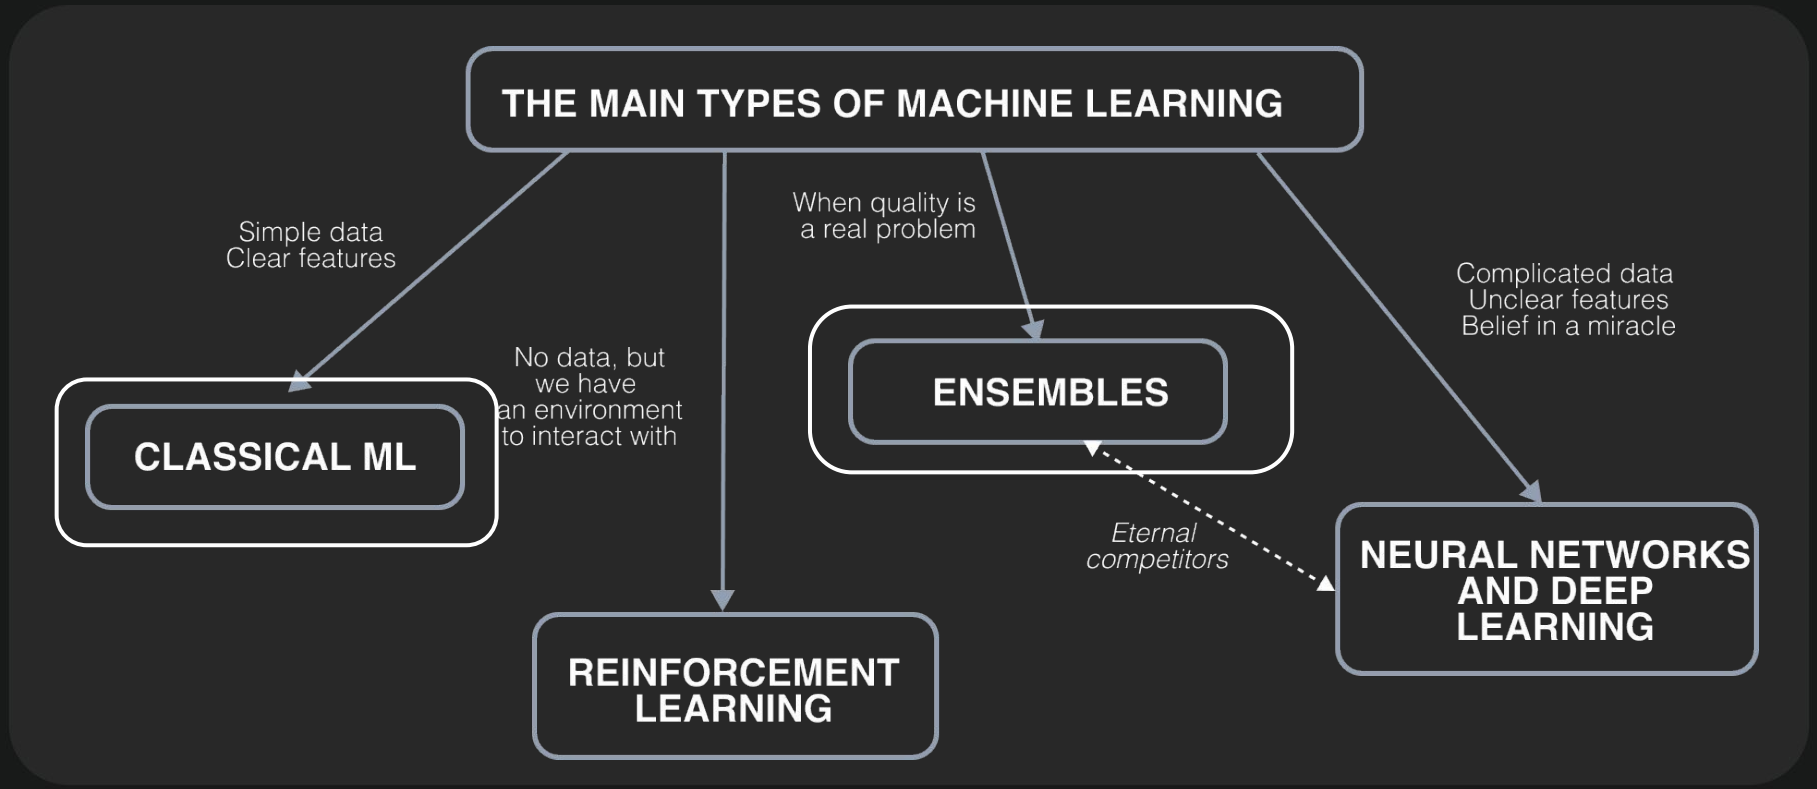

CLASSICAL MACHINE LEARNING

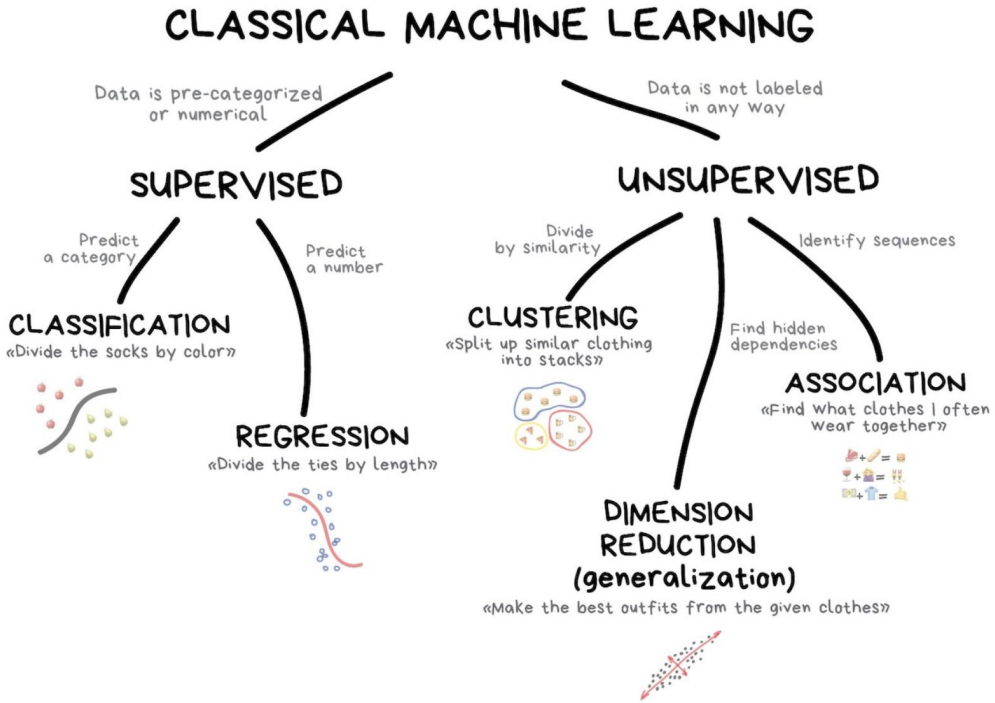

CLASSICAL MACHINE LEARNING

Supervised Learning
(Classification Algorithm)

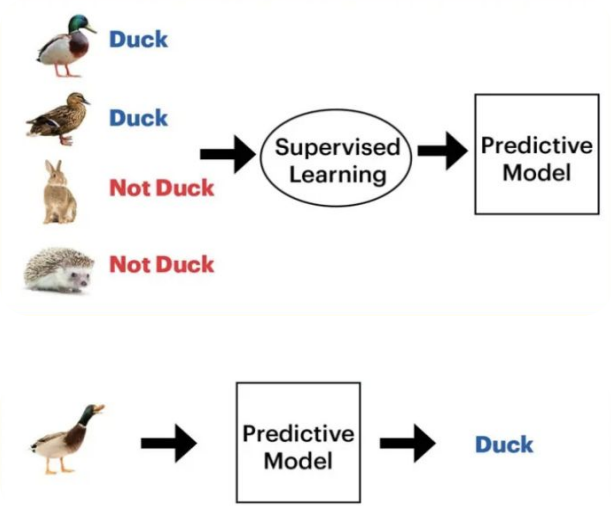

Unsupervised Learning
(Clustering Algorithm)

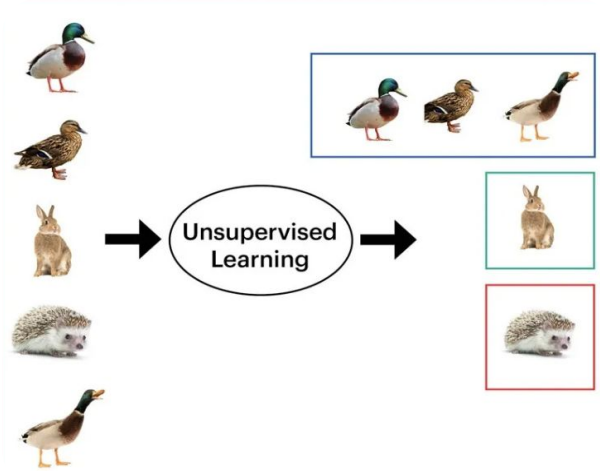

AI VS ML VS NN

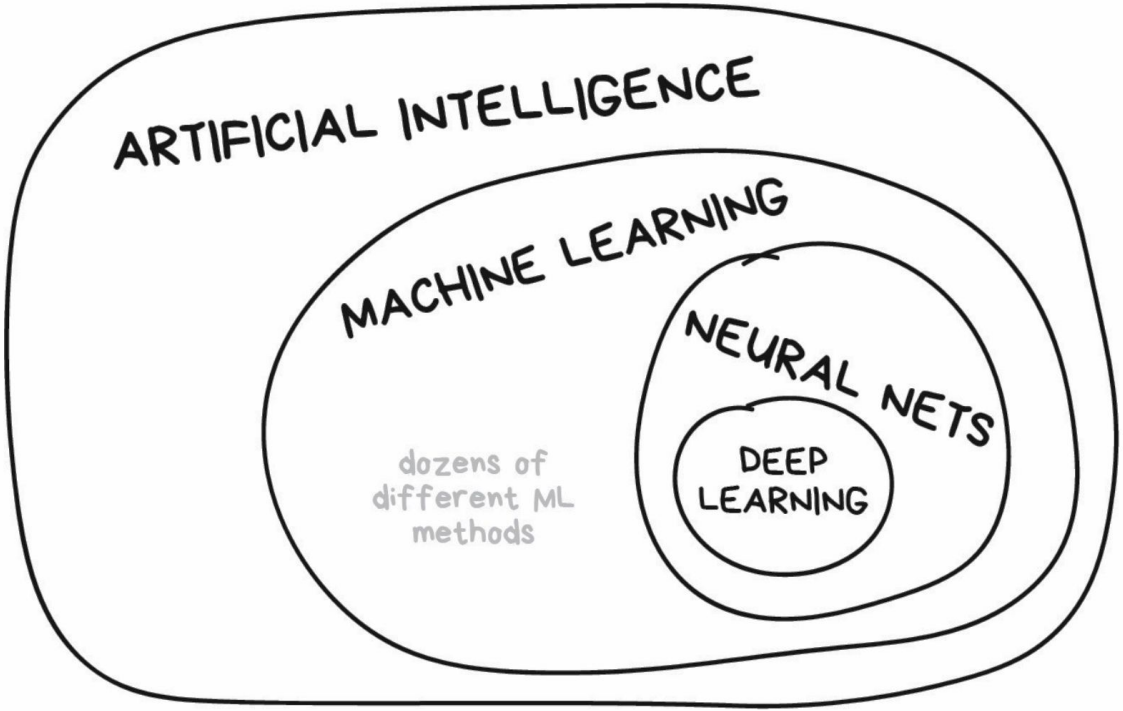
ARTIFICIAL INTELLIGENCE
MACHINE LEARNING
NEURAL NETS
DEEP LEARNING
dozens of different ML methods

DATA SCIENCE

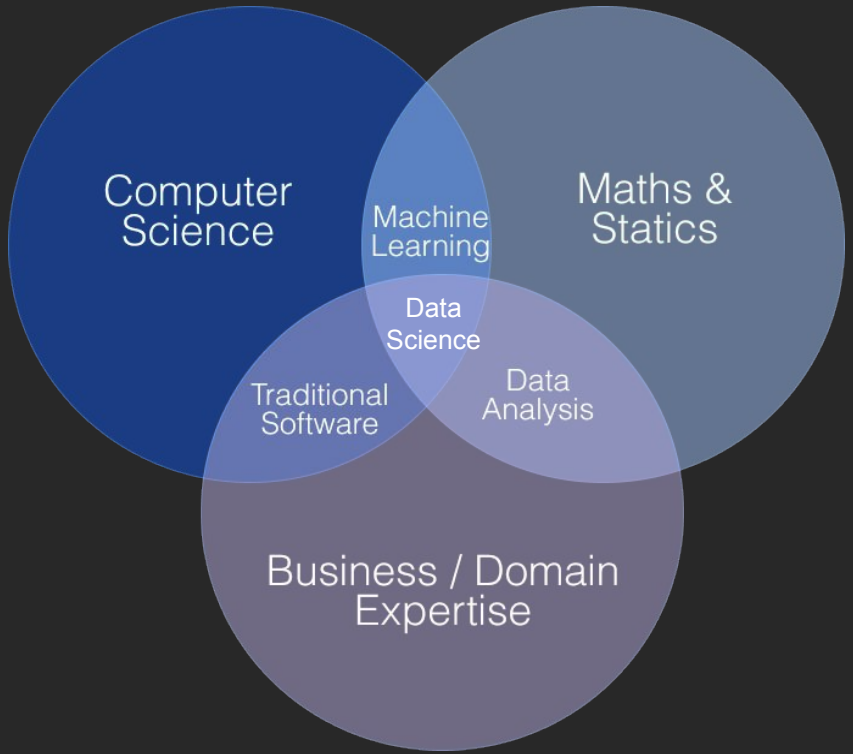

CRISP-DM

CRISP-DM — Cross-industry standard process for data mining

Міжгалузевий стандартний процес інтелектуального аналізу даних.

Дані — це центральна точка.

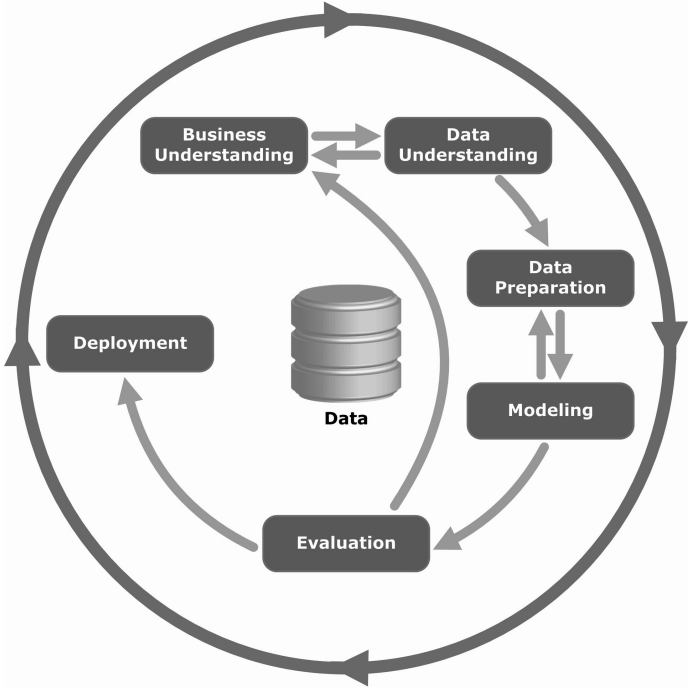

DATA IS A KEY

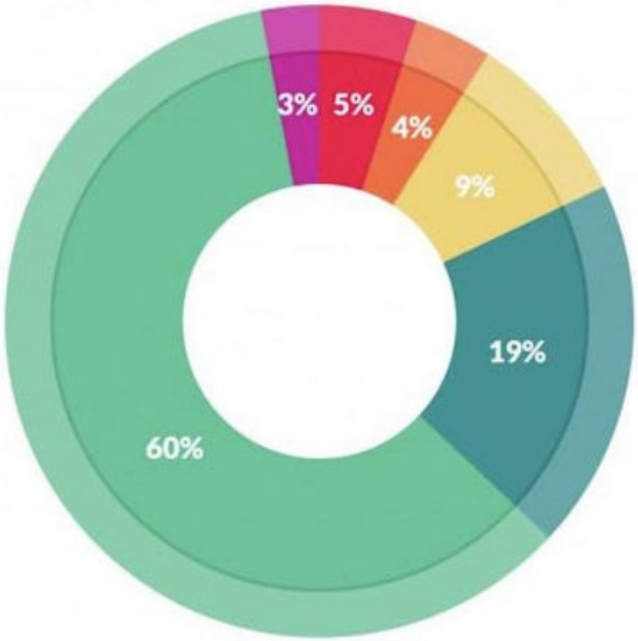

What data scientists spend the most time doing

- *Building training sets: 3%*
- *Cleaning and organizing data: 60%*
- *Collecting data sets; 19%*
- *Mining data for patterns: 9%*
- *Refining algorithms: 4%*
- *Other: 5%*

… BUT THE LEAST ENJOYABLE KEY

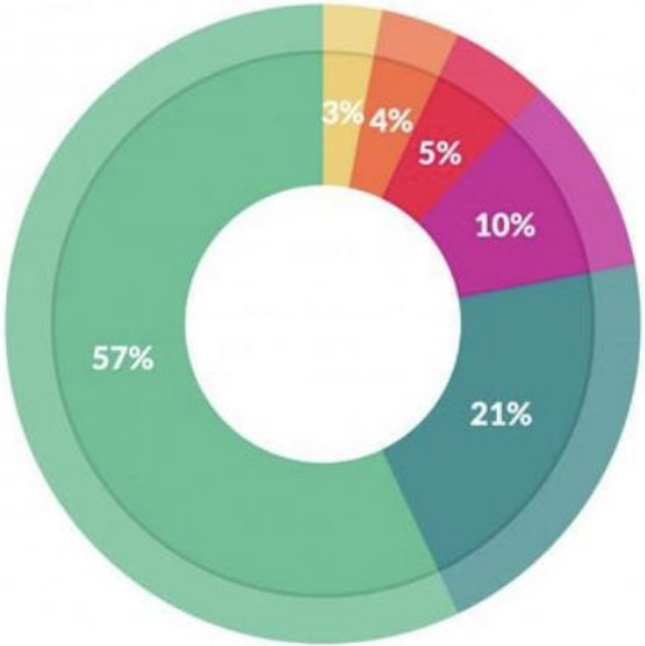

What's the least enjoyable part of data science?

- *Building training sets: 10%*
- *Cleaning and organizing data: 57%*
- *Collecting data sets: 21%*
- *Mining data for patterns: 3%*
- *Refining algorithms: 4%*
- *Other: 5%*

ЗАПИТАННЯ

ЧОМУ САМЕ PYTHON ДЛЯ DATA SCIENCE?

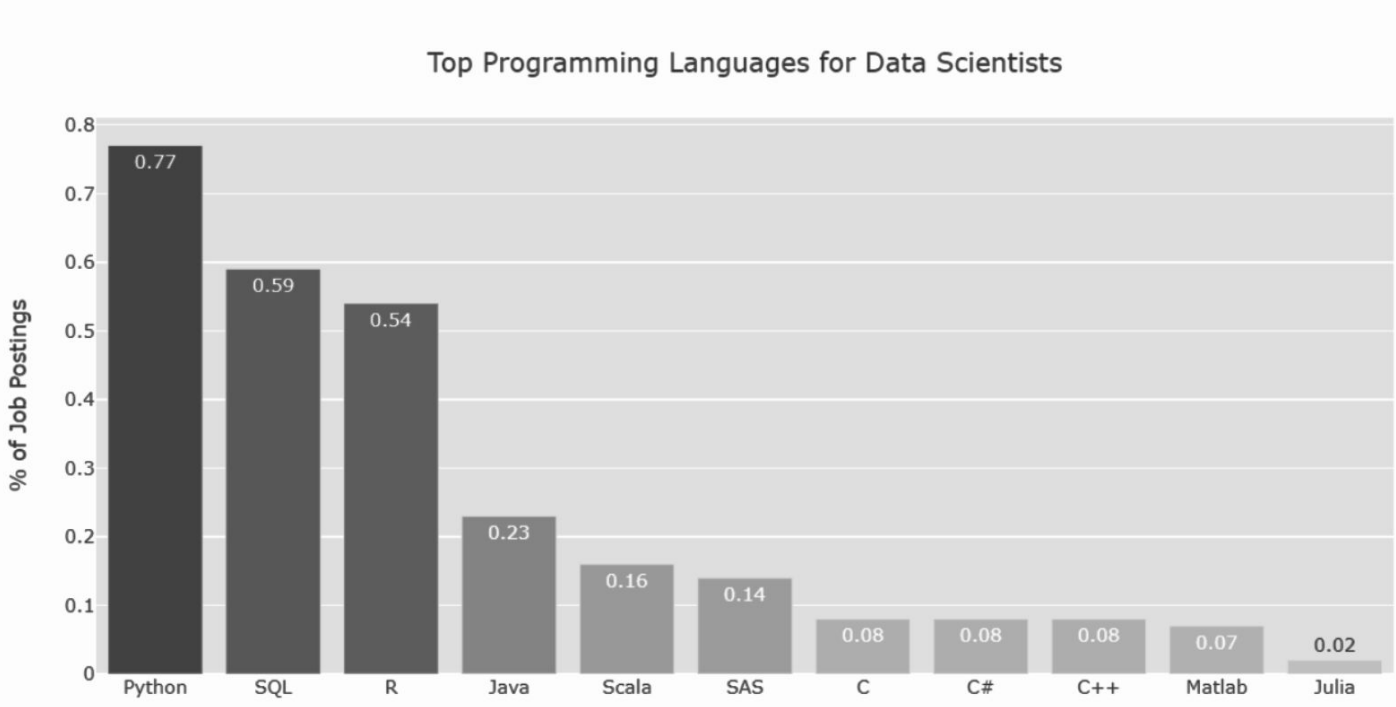

TOP PYTHON LIBRARIES FOR DATA SCIENCE

- NumPy
- Pandas
- SciPy
- Matplotlib
- scikit-learn
- Seaborn
- Plotly
- Statsmodels
- XGBoost
- ... and many more

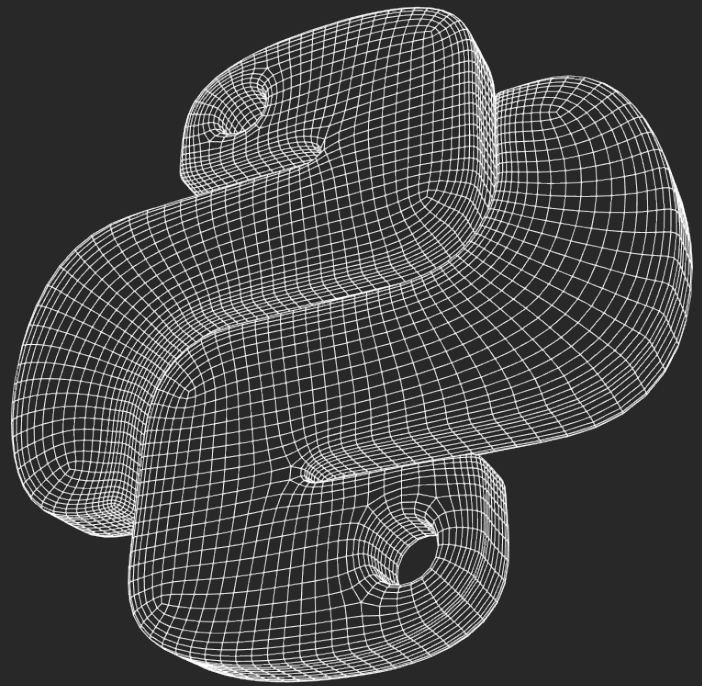

NUMPY

Numpy, скорочення від **Numerical Python**, є основним пакетом, необхідним для високопродуктивних наукових обчислень і аналізу даних в екосистемі Python.

Це основа, на якій побудовані майже всі інструменти вищого рівня, як-от Pandas і scikit-learn.

TensorFlow використовує масиви NumPy як фундаментальний будівельний блок, на основі якого вони побудували свої об’єкти Tensor і графічний потік для завдань глибокого навчання (Deep Learning) (де активно використовують операції лінійної алгебри над довгим списком/вектором/матрицею чисел).

NUMPY

NumPy надає два фундаментальні об’єкти:

- N-dimensional array object (ndarray) є однорідною колекцією «елементів», проіндексованих за допомогою N цілих чисел. Є два важливих параметра, які визначають N-вимірний масив:
  - форма масиву
  - тип елемента, з якого складається масив

- A universal function object (ufunc). NumPy надає безліч математичних функцій, які працюють з ndarray object. Від алгебраїчних функцій, як-от додавання та множення, до тригонометричних функцій, як-от sin і cos. Усі ufunc завжди виконуються поелементно.

NUMPY IS FAST. VECTORIZATION AND BROADCASTING

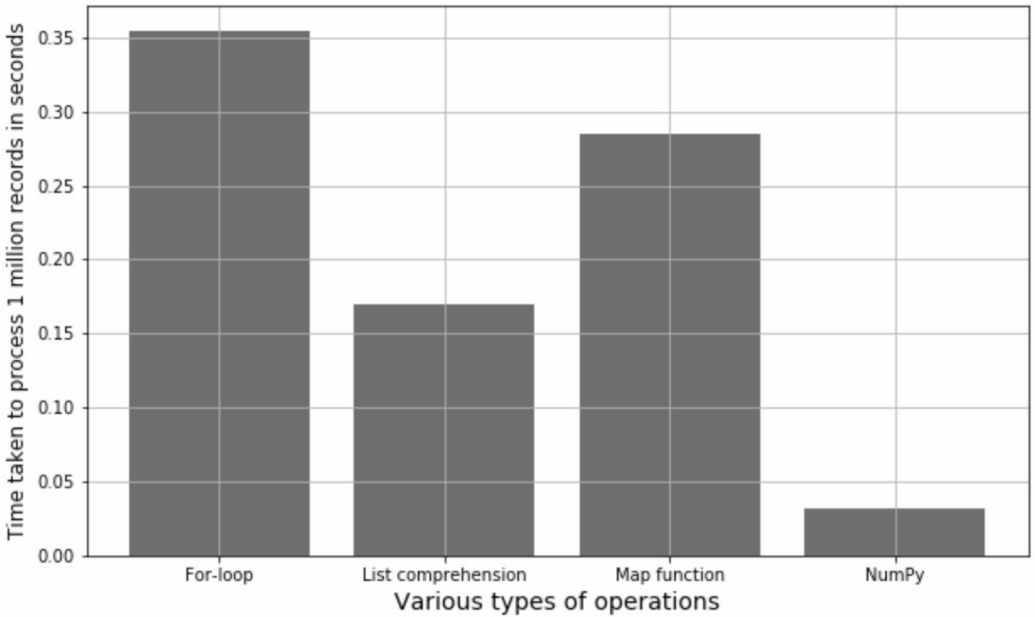

Bar chart of comparative speeds of execution of simple mathematical operations

VECTORIZATION

Vectorization (векторизація) — це потужна здатність у NumPy виражати операції над цілими масивами, а не їх окремими елементами.

Під час циклічного перегляду масиву чи будь-якої структури даних у Python виникає багато накладних витрат. Векторизовані операції в NumPy делегують внутрішній цикл високооптимізованим функціям C і Fortran, що робить код Python чистішим і швидшим.

BROADCASTING (ТРАНСЛЯЦІЯ)

Термін broadcasting (трансляція) описує, як NumPy обробляє масиви різної форми під час арифметичних операцій. З урахуванням певних обмежень менший масив «broadcast» («транслюється») через більший масив, щоб вони мали сумісні форми. Трансляція забезпечує засоби векторизації операцій з масивами, щоб цикли відбувалися в C замість Python.

BROADCASTING (ТРАНСЛЯЦІЯ)

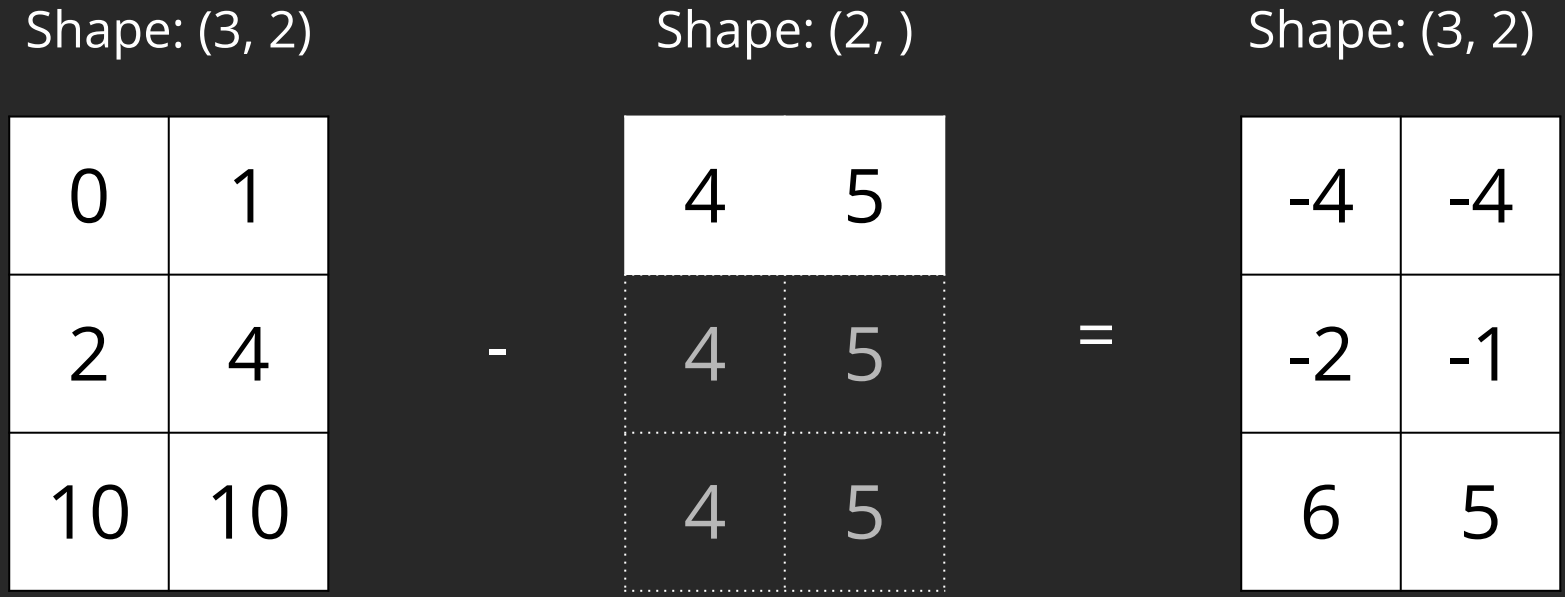

/LIVE CODING:

Q&A