ENG-209

Data science pour ingénieur·e·s avec Python

Cours 2: Structures de données

Jean-Philippe Pellet

15 septembre 2025

Cours 2

Structures de données:
tuple, list, set, dict, dataclass

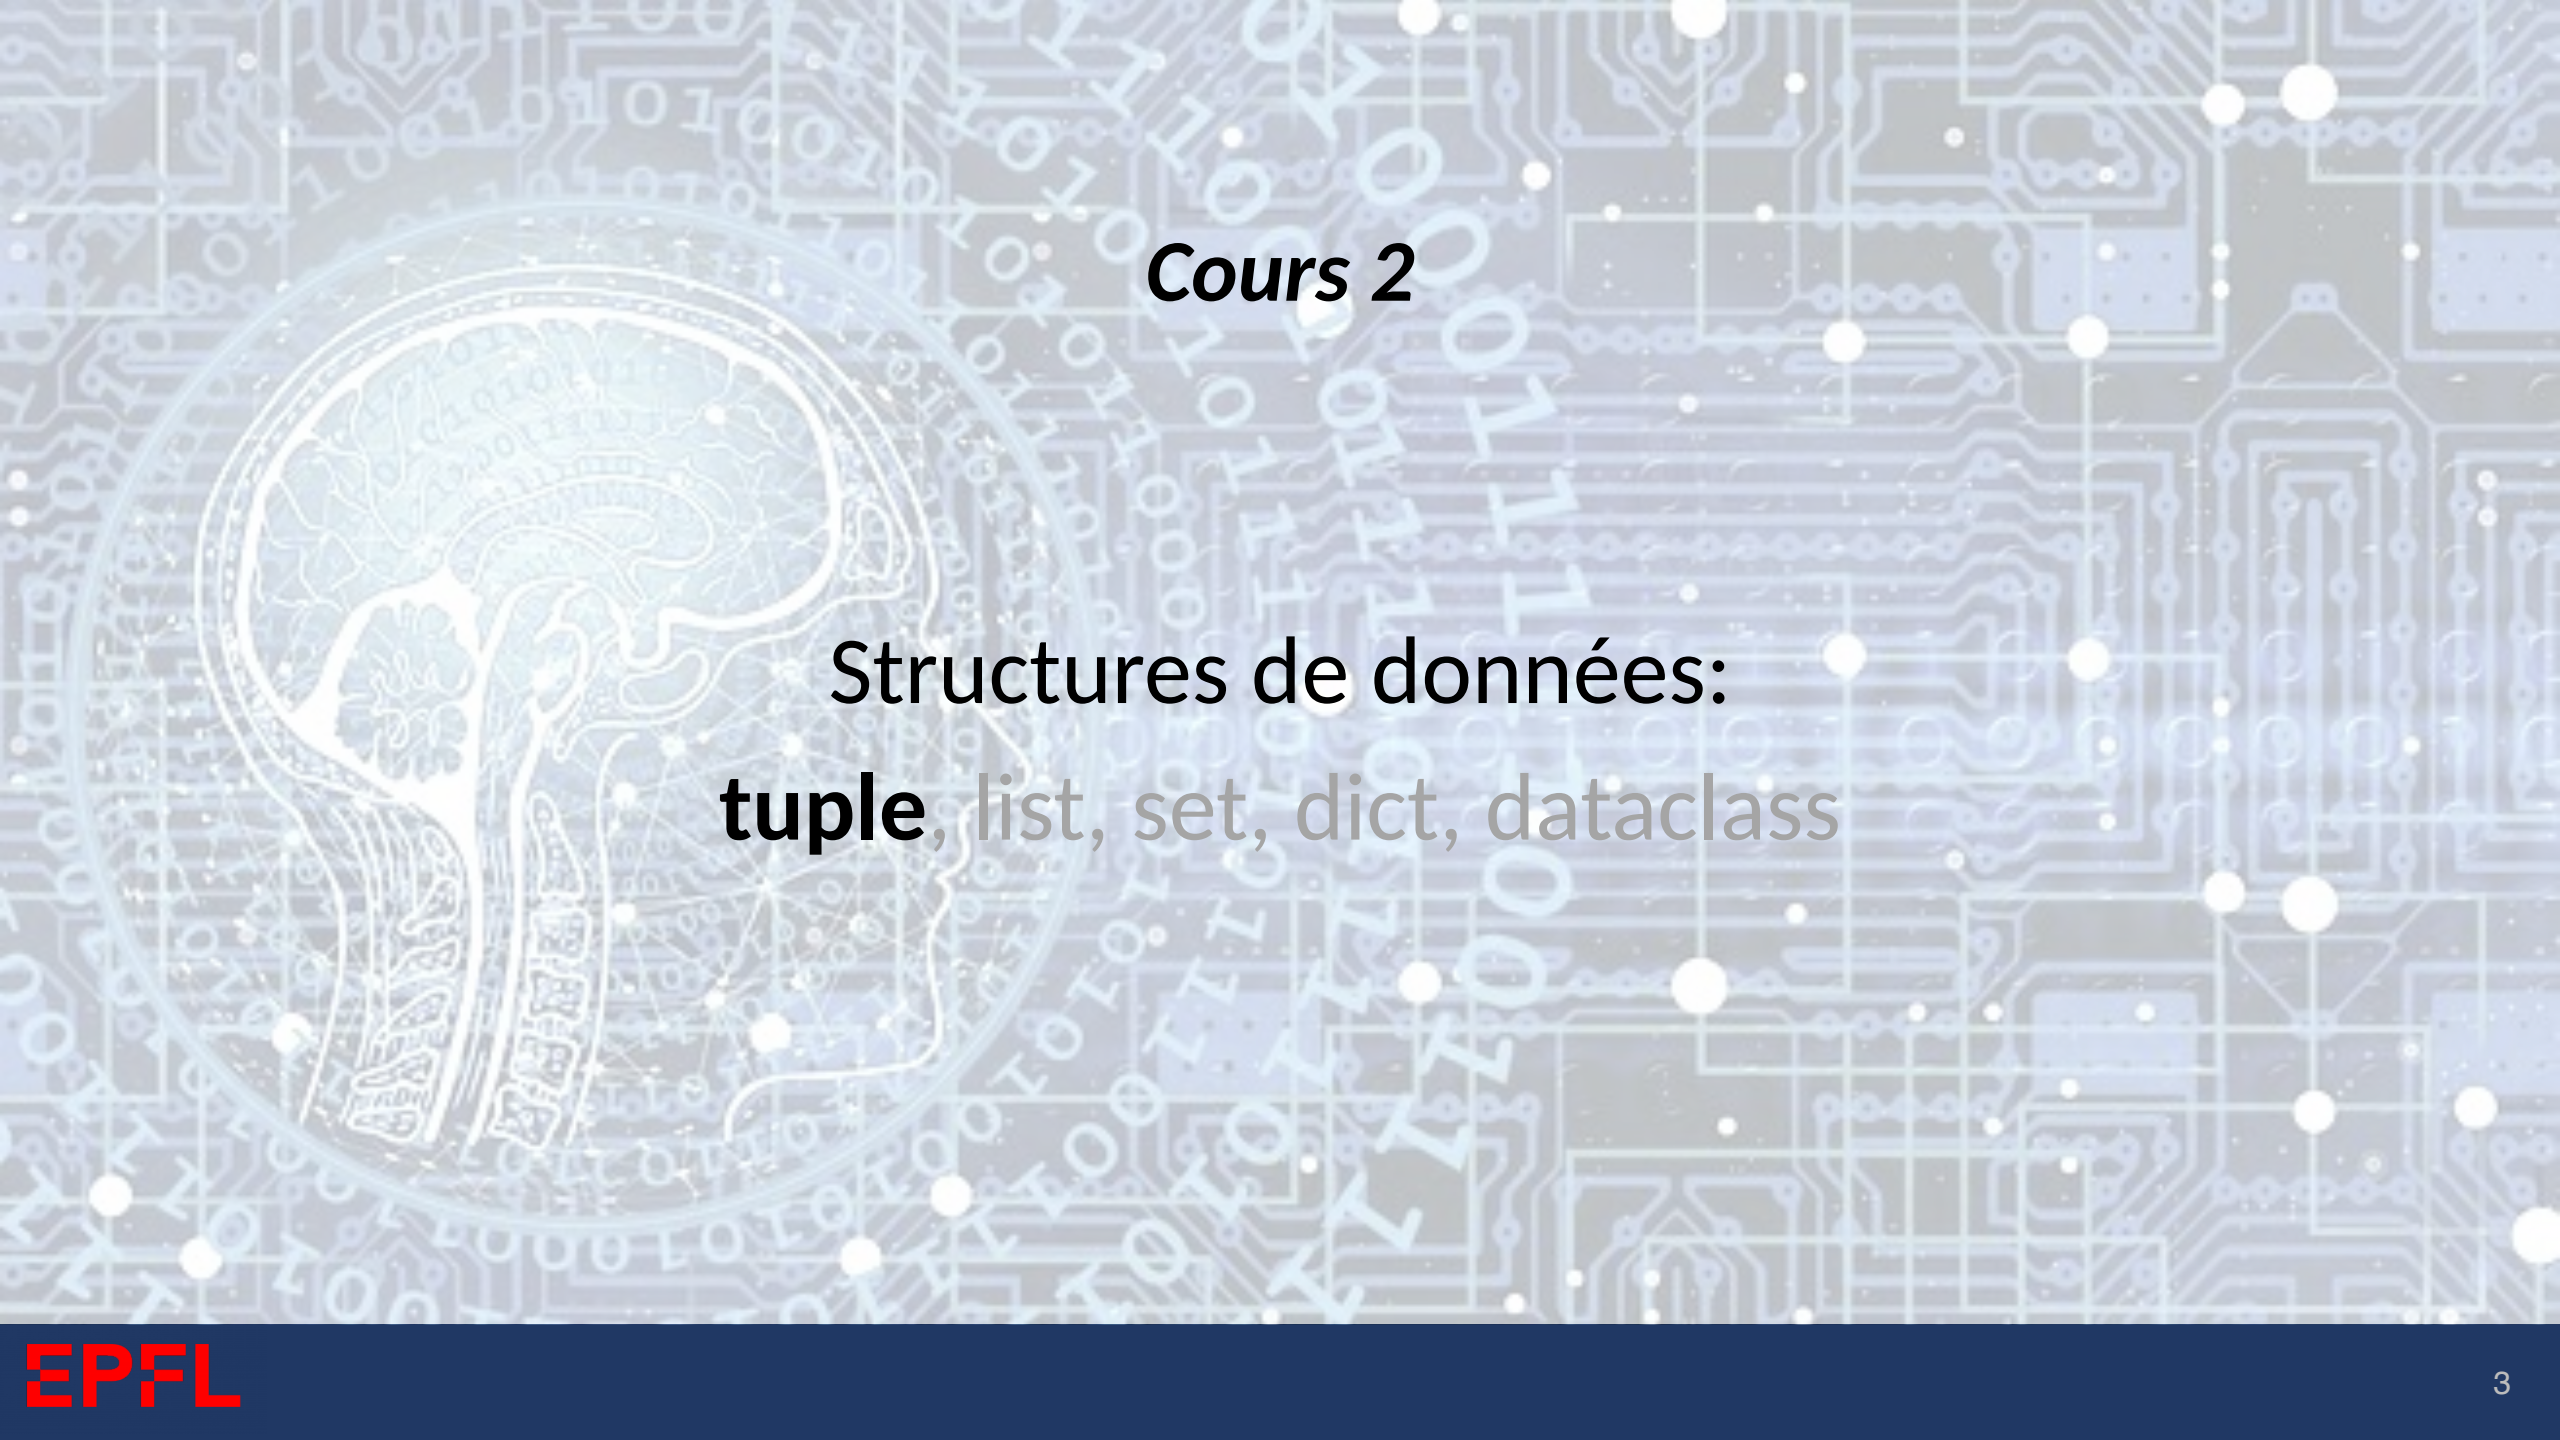

Cours 2

Structures de données:

tuple, list, set, dict, dataclass

Tuples — plusieurs valeurs ensembles

```python
my_data = ("Jean-Philippe", 1.79, 3)
```

Un tuple *peut être défini avec des parenthèses.*

```python
n = len(my_data) # 3
```

On peut demander le nombre d'éléments d'un tuple

```python
name = my_data[0]
nb_kids = my_data[2]
```

On récupère des éléments du tuple avec [x]

```python
my_data[2] = 4
```

Les tuples sont immuables (éléments pas réaffectables)

```python
two_primes = 2, 3
```

La plupart du temps, on peut aussi faire sans parenthèses

```python
a, b = b, a
```

Voici comment «swapper» deux variables en Python avec des tuples

```python
for item in my_data:    # Jean-Philippe
    print(item)         # 1.79
                        # 3
```

On peut itérer à travers des tuples avec un for *normal*

Tuples — fonctions et type

```python
def to_hours_and_minutes(hours_dec):
    hours_int = int(hours_dec)
    minutes = int((hours_dec - hours_int) * 60)
    return hours_int, minutes
```

Les tuples sont pratiques pour retourner plusieurs valeurs d'une fonction

```python
h_and_min = to_hours_and_minutes(2.5)
```

La fonction peut être appelée normalement et retourne un tuple, ici de longueur 2

```python
h, m = to_hours_and_minutes(2.5)

print(f"{h} h {m} min")
```

Le tuple peut être directement «déstructuré»: ici, on assigne les deux variables d'un coup

Les tuples ont le type générique tuple[…] *avec autant d'indication de type qu'il y a d'éléments dans le tuple*

```python
def to_hours_and_minutes2(hours_dec: float) -> tuple[int, int]:
    ...
```

«Cette fonction retourne un tuple de deux int»

Cours 2

Structures de données:

tuple, **list**, set, dict, dataclass

Listes — bases

```
temperatures = [28.7, 25.3, 22.0, 23.9, 25.8, 30.1]
```

Une liste *peut être définie avec des* [ ]

```
print(temperatures[0])
```

On accède à ses éléments avec [ ] *également, comme pour les tuples, en passant un index*

```
temperatures[0] = ...
```

Chaque «case» de la liste peut être modifiée

```
len(temperatures) # 6
```

On peut récupérer sa longueur

```
avg = 0.0
for i in range(len(temperatures)):
    avg += temperatures[i]
avg /= len(temperatures)
```

On peut itérer à travers, par exemple pour calculer sa moyenne…

```
avg = 0.0
for t in temperatures:
    avg += t
avg /= len(temperatures)
```

… mais à la place de range(len(…))*, on utilisera plutôt une itération directe sur les éléments*

Listes — fonctions et méthodes

```
temperatures = [28.7, 25.3, 22.0, 23.9, 25.8, 30.1]

max(temperatures) # 30.1
min(temperatures) # 22.0
```

Il y a une série de fonctions prédéfinies qui sont applicables aux listes: max, min, sum*, etc.*

```
from statistics import mean, stdev

mean(temperatures)  # 25.96666666666667
stdev(temperatures) # 3.0011109054259673
```

*Certaines autres fonctions (*mean, stdev*) font partie de la bibliothèque standard, mais sont à importer d'un module séparé*

Une série de méthodes existent pour modifier la liste et son contenu

```
temperatures.append(28.2)
temperatures.extend((25.6, 22.8, 18.5))
temperatures.sort()
temperatures.clear()
```

*Ajout d'un seul (*append*) ou de plusieurs éléments (*extend*, en passant ici un tuple) à la fin de la liste*

Tri

Effaçage, etc.

Listes — subscripting, slicing

```
temperatures = [28.7, 25.3, 22.0, 23.9, 25.8, 30.1]
```

```
temperatures[0:3] # [28.7, 25.3, 22.0]
```

On peut extraire une partie des éléments en passant un slice *à la place d'un index unique entre* [ ]

```
temperatures[:3]  # idem
```

On peut omettre le premier index si c'est 0

```
temperatures[4:]  # [25.8, 30.1]
```

On peut omettre le second index s'il faut aller jusqu'à la fin de la liste

```
temperatures[-2:] # idem
```

On peut utiliser des index négatifs pour faire référence à des éléments depuis la fin de la liste

```
temperatures[0:2] = [27.8, 23.5]
```

Avec des slices, on peut modifier plusieurs cases à la fois

```
temperatures[0:2] = []
```

On peut également en supprimer…

```
temperatures[0:0] = [27.8, 23.5]
```

… et en insérer (ici au début)

```
temperatures[0] = [27.8, 23.5]
```

Attention, ceci n'a pas le même effet, et stocke une liste complète à la position 0 de la liste principale

Listes — compréhensions de listes (1/2)

```
words = ["Elvis", "has", "left", "the", "building"]
size_of_words = [len(word) for word in words]
print(size_of_words) # [5, 3, 4, 3, 8]
```

Génération rapide d'une liste selon le format:
[<expr> **for** <generator>]
Très pratique pour créer des listes dérivées

```
[0 for _ in range(10)]
# [0, 0, 0, 0, 0, 0, 0, 0, 0, 0]
```

On peut nommer la variable _ (simple convention) si l'on n'a pas besoin de sa valeur

```
points = [2, 2, 5, 6, 1, 6, 3, 2]
[p for p in points if p > 3]
# donne [5, 6, 6]
```

On peut sauter la génération de certaines valeurs avec un filtre en incluant un **if** *après le* **for**

```
~~range(0, 10, 0.1)~~
[x / 10 for x in range(0, 100)]
# [0.0, 0.1, 0.2, ..., 9.8, 9.9]
```

Voici comment on pourrait générer une range *de floats, ce qui n'est pas possible avec la fonction de base*

Listes — compréhensions de listes (2/2) et type

```
firsts = ["Jean", "Pierre"]
seconds = ["Pierre", "Michel", "Marc", "Jean"]
[f"{f}-{s}" for f in firsts for s in seconds if f != s]
# ['Jean-Pierre', 'Jean-Michel', 'Jean-Marc',
#  'Pierre-Michel', 'Pierre-Marc', 'Pierre-Jean']
```

On peut avoir plusieurs générateurs et plusieurs filtres. Ici, on génère toutes les combinaisons de noms composés possibles tant que la première partie est différente de la seconde

```
[[x * y for y in range(1, 11)] for x in range(2, 11)]
# [[2, 4, 6, ..., 18, 20], [3, 6, ..., 30], …,
#  [10, 20, ..., 100]]
```

On peut générer des listes imbriquées, par exemple si l'expression déterminant la valeur de chaque case de la liste est elle-même une compréhension de listes

```
words:    list[str] = ...
my_ints: list[int] = ...

mult_table: list[list[int]] = ...
```

Pour indiquer les types, on utilise list[…] *avec un paramètre de type*

Exemple d'un type de liste imbriquée

Cours 2

Structures de données:

tuple, list, **set**, dict, dataclass

Sets — bases

```python
numbers = {2, 3, 3, 4, 2, 5}
print(numbers) # {2, 3, 4, 5}

print(numbers[0])

for n in numbers:
    print(n)

if 5 in numbers:
    print("5 is in the set")
    numbers.remove(5)



empty_set = set()


numbers: set[int] = ...
```

Un set *peut être défini avec des* { }

Chaque élément y apparaît au plus une fois

Impossible de récupérer l'élément n, pas d'ordre intrinsèque…

… mais possible d'itérer à travers

Opération optimisée (O(1)): déterminer si un élément est oui ou non dans un set donné

Une série de méthodes existent: remove(), add(), clear(), *mais aussi* difference(), intersection(), issuperset(), issubset()

Un set vide s'écrit set(), *parce que* {} *est le dictionnaire vide, pas le set vide*

Le type paramétrique est set[…]

Types linéaires, conversions

On peut convertir entre différentes structures de données, dans des cas simples avec list(…) *et* set(…)

```
list(range(10))
# [0, 1, 2, 3, 4, 5, 6, 7, 8, 9]
```

Conversion d'une range *en liste*

```
my_data = ("Jean-Philippe", 1.79, 3)
list(my_data)
# ['Jean-Philippe', 1.79, 3]
```

Conversion d'un tuple en liste hétérogène (pas forcément recommandé)

```
numbers = [2, 3, 3, 4, 2, 5]
numbers = list(set(numbers))
# [2, 3, 4, 5]
```

Conversion d'une liste en set puis de nouveau en liste afin d'avoir une liste normale mais sans valeurs répétées

Cours 2

Structures de données:

tuple, list, set, **dict**, dataclass

Dict — bases

```python
ages = {"Alex": 12, "Emelyne": 10, "Victor": 8}


print(ages["Alex"])       # 12
print(ages["Sandra"])

# seulement si la clé est présente
if "Sandra" in ages:
    print(ages["Sandra"])
else:
    print("n/a")

ages.get("Sandra", -1)


ages["Nathan"] = 5

del ages["Nathan"]
```

Un dict *relie des clés (ici des noms) à des valeurs (ici des âges). Il peut être défini avec des* { }*, des* : *pour relier chaque clé à sa valeur*

Il est optimisé pour retourner rapidement (O(1)) la valeur liée à une clé

À moins qu'on ne le sache pour sûr, on doit s'assurer de la présence d'une valeur avec l'opérateur in

On peut aussi utiliser la méthode get()*, qui permet d'indiquer une valeur par défaut à retourner si la clé n'est pas trouvée*

On peut mettre à jour le dictionnaire en ajoutant des «lignes», en en modifiant…

… et en en supprimant

Dict — itération et type

```python
for key in ages:
    print(key)      # Alex
                    # Emelyne
                    # Victor
```

Une itération avec un simple for *sur le dictionnaire revient à itérer à travers les clés*

```python
for key, value in ages.items():
    print(f"{key} -> {value}")

                    # Alex -> 11
                    # Emelyne -> 9
                    # Victor -> 7
```

On peut itérer sur une «vue» du dictionnaire comme une séquence de paires, et chaque itération livre à la fois la clé et la valeur associée

```python
ages: dict[str, int] = ...
```

Pour définir le type d'un dictionnaire, on indique à la fois le type des clés et le type des valeurs

Dict — defaultdict

```python
from collections import defaultdict


hours_worked: list[tuple[str, int]] = [
    ("Jane", 8),
    ("John", 8),
    ("Jane", 10),
    ("Jane", 4),
    ("John", 7),
]

totals: defaultdict[str, int] = defaultdict(int)

for name, hours in hours_worked:
    totals[name] += hours

print(totals["Jane"]) # 22
print(totals["Mary"]) # 0
```

Un defaultdict *assigne une valeur par défaut à une nouvelle clé qu'il ne connaît pas.*

Exemple: une liste de combien d'heures 2 personnes ont travaillé. On demande les totaux par nom

On crée un defaultdict *avec comme valeur par défaut* **int()**, *donc 0, obtenu via l'argument* int *de* defaultdict

En accumulant les totaux, pas besoin de prendre en compte le cas où la clé n'est pas encore connue

Le dict répond (et insère) 0 s'il ne connaît pas la clé, par exemple ici pour Mary.

Cours 2

Structures de données:

tuple, list, set, dict, **dataclass**

Données simples: les *dataclasses*

```python
from dataclasses import dataclass

@dataclass
class Person:
    first_name: str
    last_name: str
    height: float
    num_children: int = 0

    @property
    def full_name(self) -> str:
        return f"{self.first_name} {self.last_name}"

p = Person("Jean-Philippe", "Pellet", 1.79, 3)
p.num_children += 1

p2 = Person("Zoé", "Zufferey", 1.72)

print(p2.full_name) # Zoé Zufferey
```

Une classe déclarée ainsi avec l'annotation @dataclass *est conçue pour représenter des données de manière flexible et convient bien à une modélisation de base d'un problème*

Chaque attribut avec son type est indiqué dans le corps de la classe, de façon indentée. En Python, tout est public (pas de concept de private *ou* protected*)*

On utilise la notation standard pour les méthodes pour définir des attributs dérivés, avec l'annotations @property

On crée des instances comme pour un tuple nommé…

… et, cette fois, on a le droit de tout modifier.

On peut indiquer facilement des valeurs par défaut pour les attributs…
… ainsi que des attributs/propriétés dérivés

Plus sur les méthodes

```python
from dataclasses import dataclass
import math

@dataclass(order=True)
class Point:
    x: float
    y: float
    z: float

    def distanceTo(self, other: 'Point') -> float:
        dx = self.x - other.x
        dy = self.y - other.y
        dz = self.z - other.z
        return math.sqrt(dx * dx + dy * dy + dz * dz)

p1 = Point(0, 0, 0)
p2 = Point(1, 1, 0)

print(p1.distanceTo(p2)) # 1.4142135623730951
```

Les méthodes sont des fonctions liées à une classe, qui reçoivent automatiquement comme premier argument l'objet sur lequel la méthode est appelée

Cet exemple modélise un point en 3 dimensions et déclare une méthode pour calculer la distance à un autre point donné, passé en paramètre. order=True *fait en sorte que des instances soit comparables avec* < *ou* >

Une méthode doit toujours définir self *comme premier argument, ce qui permet d'accéder aux attributs (ressemble à* this *dans d'autres langages. D'autre arguments peuvent être définis; le type peut être spécifié (ici entre '…' parce que faisant référence à au type de la classe en cours de définition)*

Deux points sont créés

L'appel de la méthode ne mentionne pas explicitement self

Programmation orientée objet en Python

- **Les classes peuvent hériter d'autres classes**
  - ✦ Héritage multiple possible, comme en C++
- **Le pendant du constructeur est la méthode spéciale __*init*__**
  - ✦ Elle est générée automatiquement pour les dataclasses
- **Toutes les méthodes doivent déclarer *self* comme paramètre**
  - Elles font référence aux attributs/champs et appellent d'autres méthodes via ce *self*
- **Rien n'est privé, tout est public: notion de l'encapsulation basée sur conventions**
  - Un attribut qui commence par _ est considéré comme «plutôt privé», à ne pas toucher
  - Un attribut qui commence par __ est considéré comme «très privé»

Résumé du cours d'aujourd'hui

- **Les tuples sont définis avec des ( )** — voire sans
  - ✦ Immuables, éléments potentiellement hétérogènes
- **Les listes sont définies avec des [ ]**
  - ✦ Hautement flexibles; en général, contenant des éléments d'un même type
- **Les sets et les dicts sont définis avec des { }**
  - ✦ Les éléments (pour les sets) ou les clés (pour les dicts) sont uniques
    - ✳ Pas de restrictions sur ce que peuvent être les valeurs des dicts
  - ✦ Les *defaultdicts* sont pratiques pour fournir une valeur par défaut
- **Les compréhensions de listes et de sets rendent certaines transformations faciles et concises**
- **Pour modéliser des types plus complexes, les dataclasses sont très pratiques** (il y a aussi NamedTuples, immuables, et les classes normales)

Autoévaluation — objectifs

- **Je suis capable de/d'…**
  - déclarer et manipuler des tuples
  - déclarer et manipuler des listes en utilisant [ ] pour récupérer ou mettre à jour **un** (avec un index simple) ou **des** (avec du slicing) élément(s)
  - créer des listes dérivées avec la syntaxe des compréhensions de listes
  - déclarer et manipuler des sets
  - déclarer et manipuler des dicts, repérer quand un defaultdict aurait du sens
  - itérer à travers ces structures de données et convertir de l'une à l'autre
  - insérer les types de ces structures de données
  - argumenter pourquoi je choisis plutôt un tuple, une list ou un set pour résoudre un problème donné
  - déclarer et manipuler des *dataclasses*
  - énoncer les limites des unes et des autres structures vues aujourd'hui

Procédure pour les exercices

- **Si tout fonctionnait la semaine passée:**
  - Exécutez le fichier “setup.sh” dans votre dossier eng209_2025 comme montré sur la vidéo sur Moodle (“Run as program”)
  - Vous obtenez le corrigé de la semaine passée et le fichier de cette semaine
- **Si vous aviez des soucis la semaine passée:**
  - Téléchargez et faites tourner “setup_traditional.sh” une fois téléchargé de Moodle
  - Réitérez ensuite l’installation normale de la semaine passée
  - Appelez-nous!