EPFL

ICC

Programmation

GC/MX, **Cours 12**

9 décembre 2022

(Enregistrement de l'année passée)

Jean-Philippe Pellet

Previously, on Programmation…

- Types de base en Python: int, float, str, bool
- Méthodes, fonctions et slicing pour calculer des valeurs dérivées
- Conditions pour exécuter du code selon la valeur d'une expression booléenne: `if <condition>: ... else: ...` et ses variantes
- Boucles pour exécuter du code plusieurs fois:
  - Boucle `while <condition>: ...`
  - Boucle `for i in range(...): ...`
- Déclaration de fonctions avec type de retour et paramètres:
  - `def calculate_area(r: float) -> float: return ...`
- Utilisation de listes, sets et dictionnaires
- Déclaration de classes: `@dataclass class Rectangle: ...`
- Création, chargement, manipulation et sauvegarde d'images
- Programmation dynamique pour trouver des seams
- Fonctions comme valeurs, paramètres; fonctions d'ordre supérieur

Cours de cette semaine

Lecture/écriture de fichiers texte
Opérations sur des chaînes de caractères

Fichiers et bytes

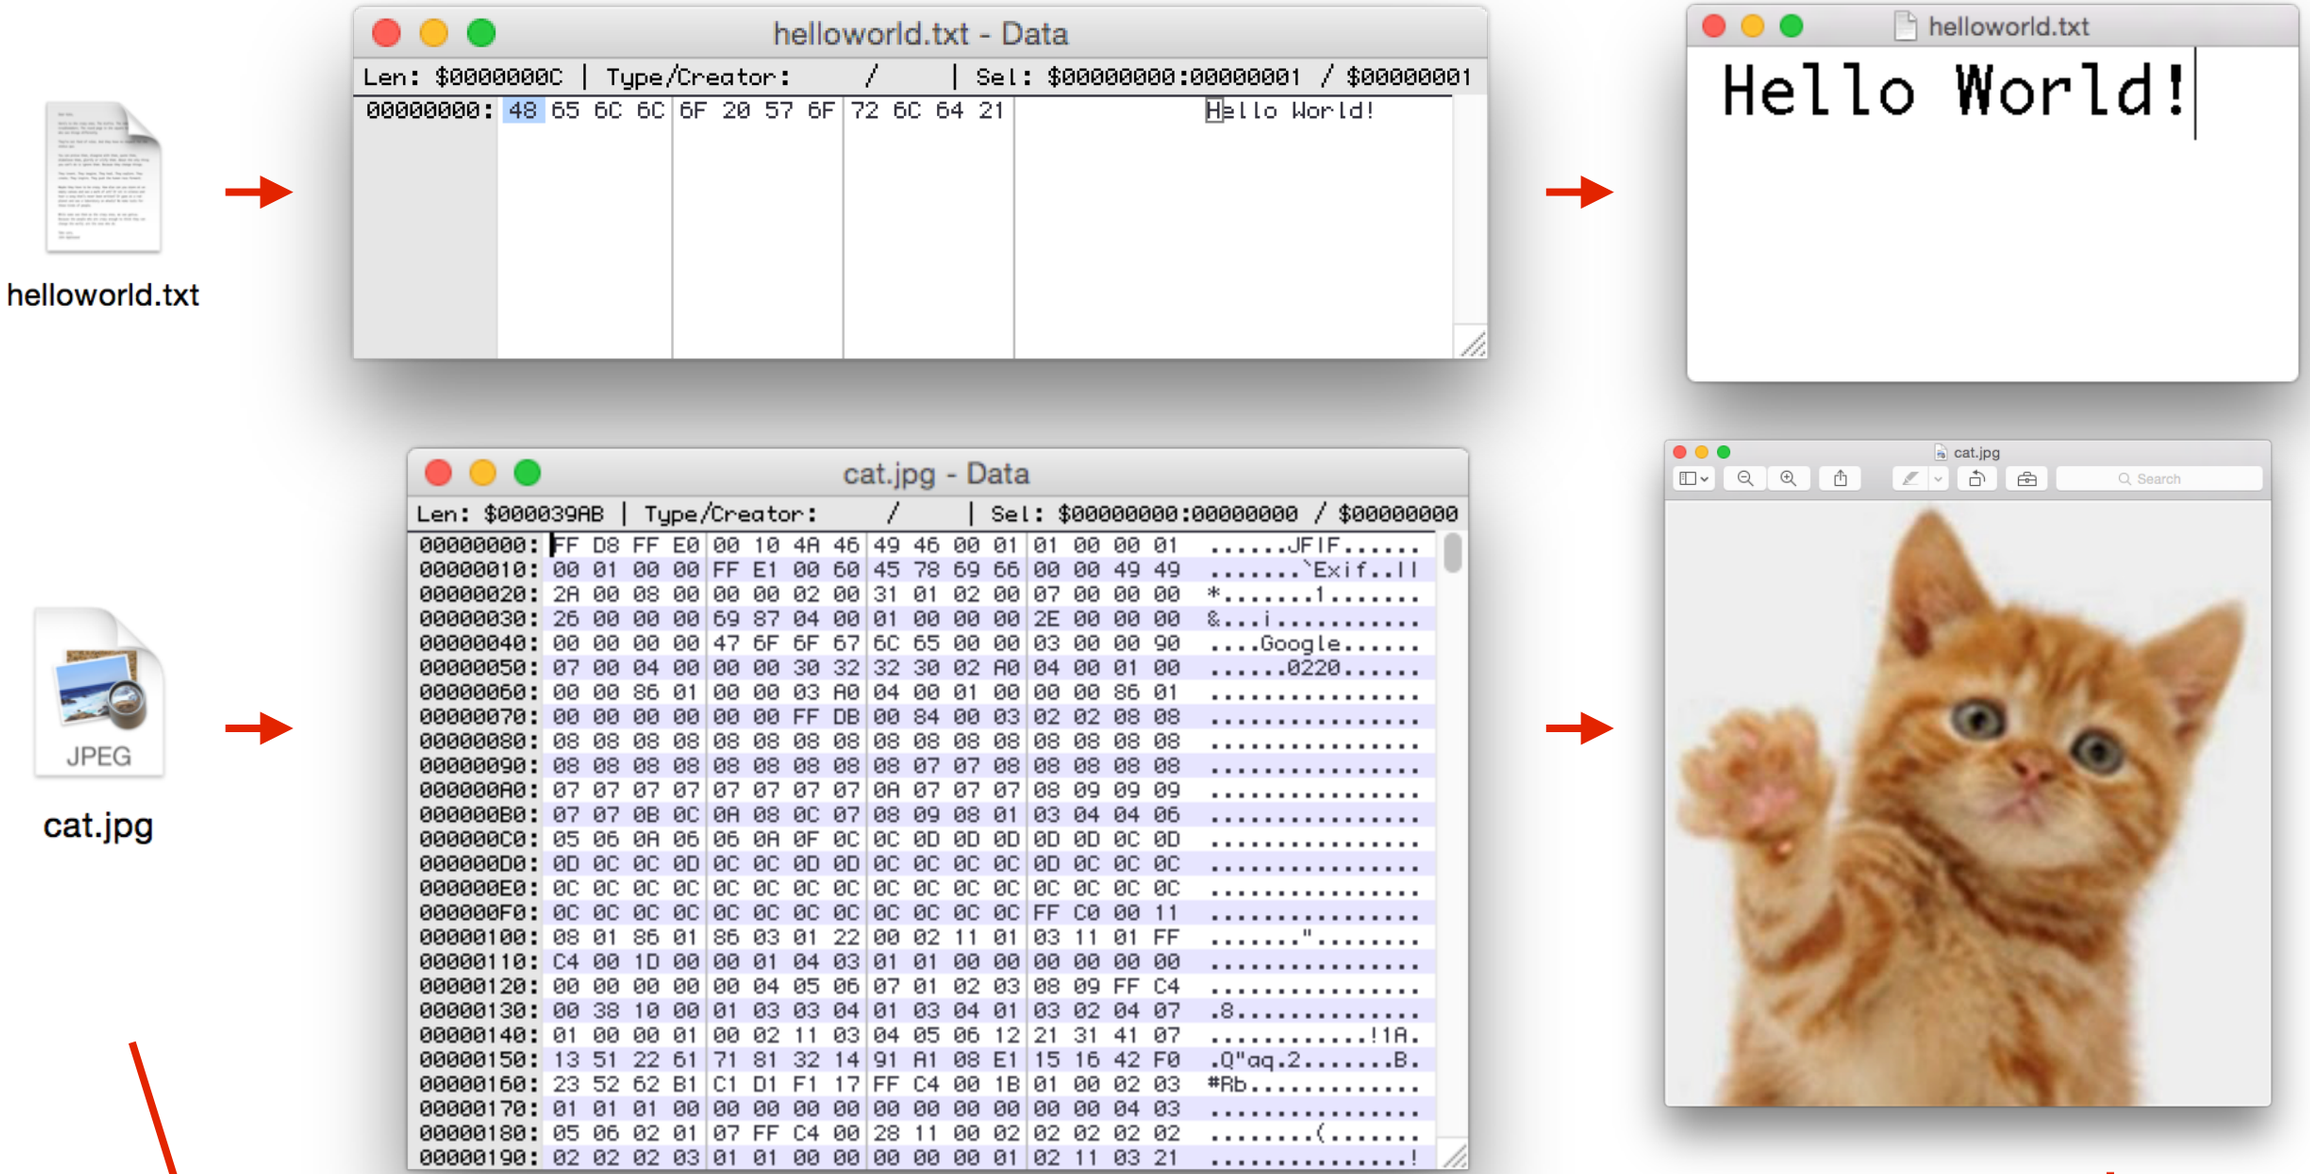

Un fichier est une séquence de bytes qui, interprétés correctement, ont du sens

Les fichiers texte

une séquence de bytes (1 byte = 8 bits)

index du byte	0	1	2	3	4	5	6	7	8	9	10	11
notation binaire	01001000	01100101	01101100	01101100	01101111	00100000	01010111	1101111	01110010	01101100	01100100	00100001
notation hexadécimale	48	65	6C	6C	6F	20	57	6F	72	6C	64	21
inter-prétation texte	**H**	**e**	**l**	**l**	**o**		**W**	**o**	**r**	**l**	**d**	**!**

+ quelques informations supplémentaires:
nom, extension/format, taille, droits d'accès, date de création,
date de la dernière modification, ..., position physique sur le disque

Le système qui interprète chaque byte (ou séquence de bytes) pour retrouver le caractère correspondant repose sur un certain encodage des caractères (Charset)

ASCII Charset

American Standard Code for Information Interchange (1963)

0	Null character
1	Start of header
...	
9	Tabulator (“\t”)
10	Line feed (“\n”)
...	
32	Space
...	
48	“0”
...	...
57	“9”

65	“A”
66	“B”
67	“C”
...	...
90	“Z”
...	
97	“a”
...	...
122	“z”
...	
127	Delete

Manquent: à, é, ä, €, ...

Unicode, UTF-8 Charset

http://fr.wikipedia.org/wiki/Unicode
http://fr.wikipedia.org/wiki/UTF-8

Unicode:
Liste avec tous les caractères qui existent,
y compris les caractères chinois, japonais, ...
(env. 1 million théoriquement, env. 120'000 utilisés)

UTF-8:
Format de codage des signes Unicode;
utilise entre 1 et 4 bytes pour un caractère

Tableau des caractères Unicode

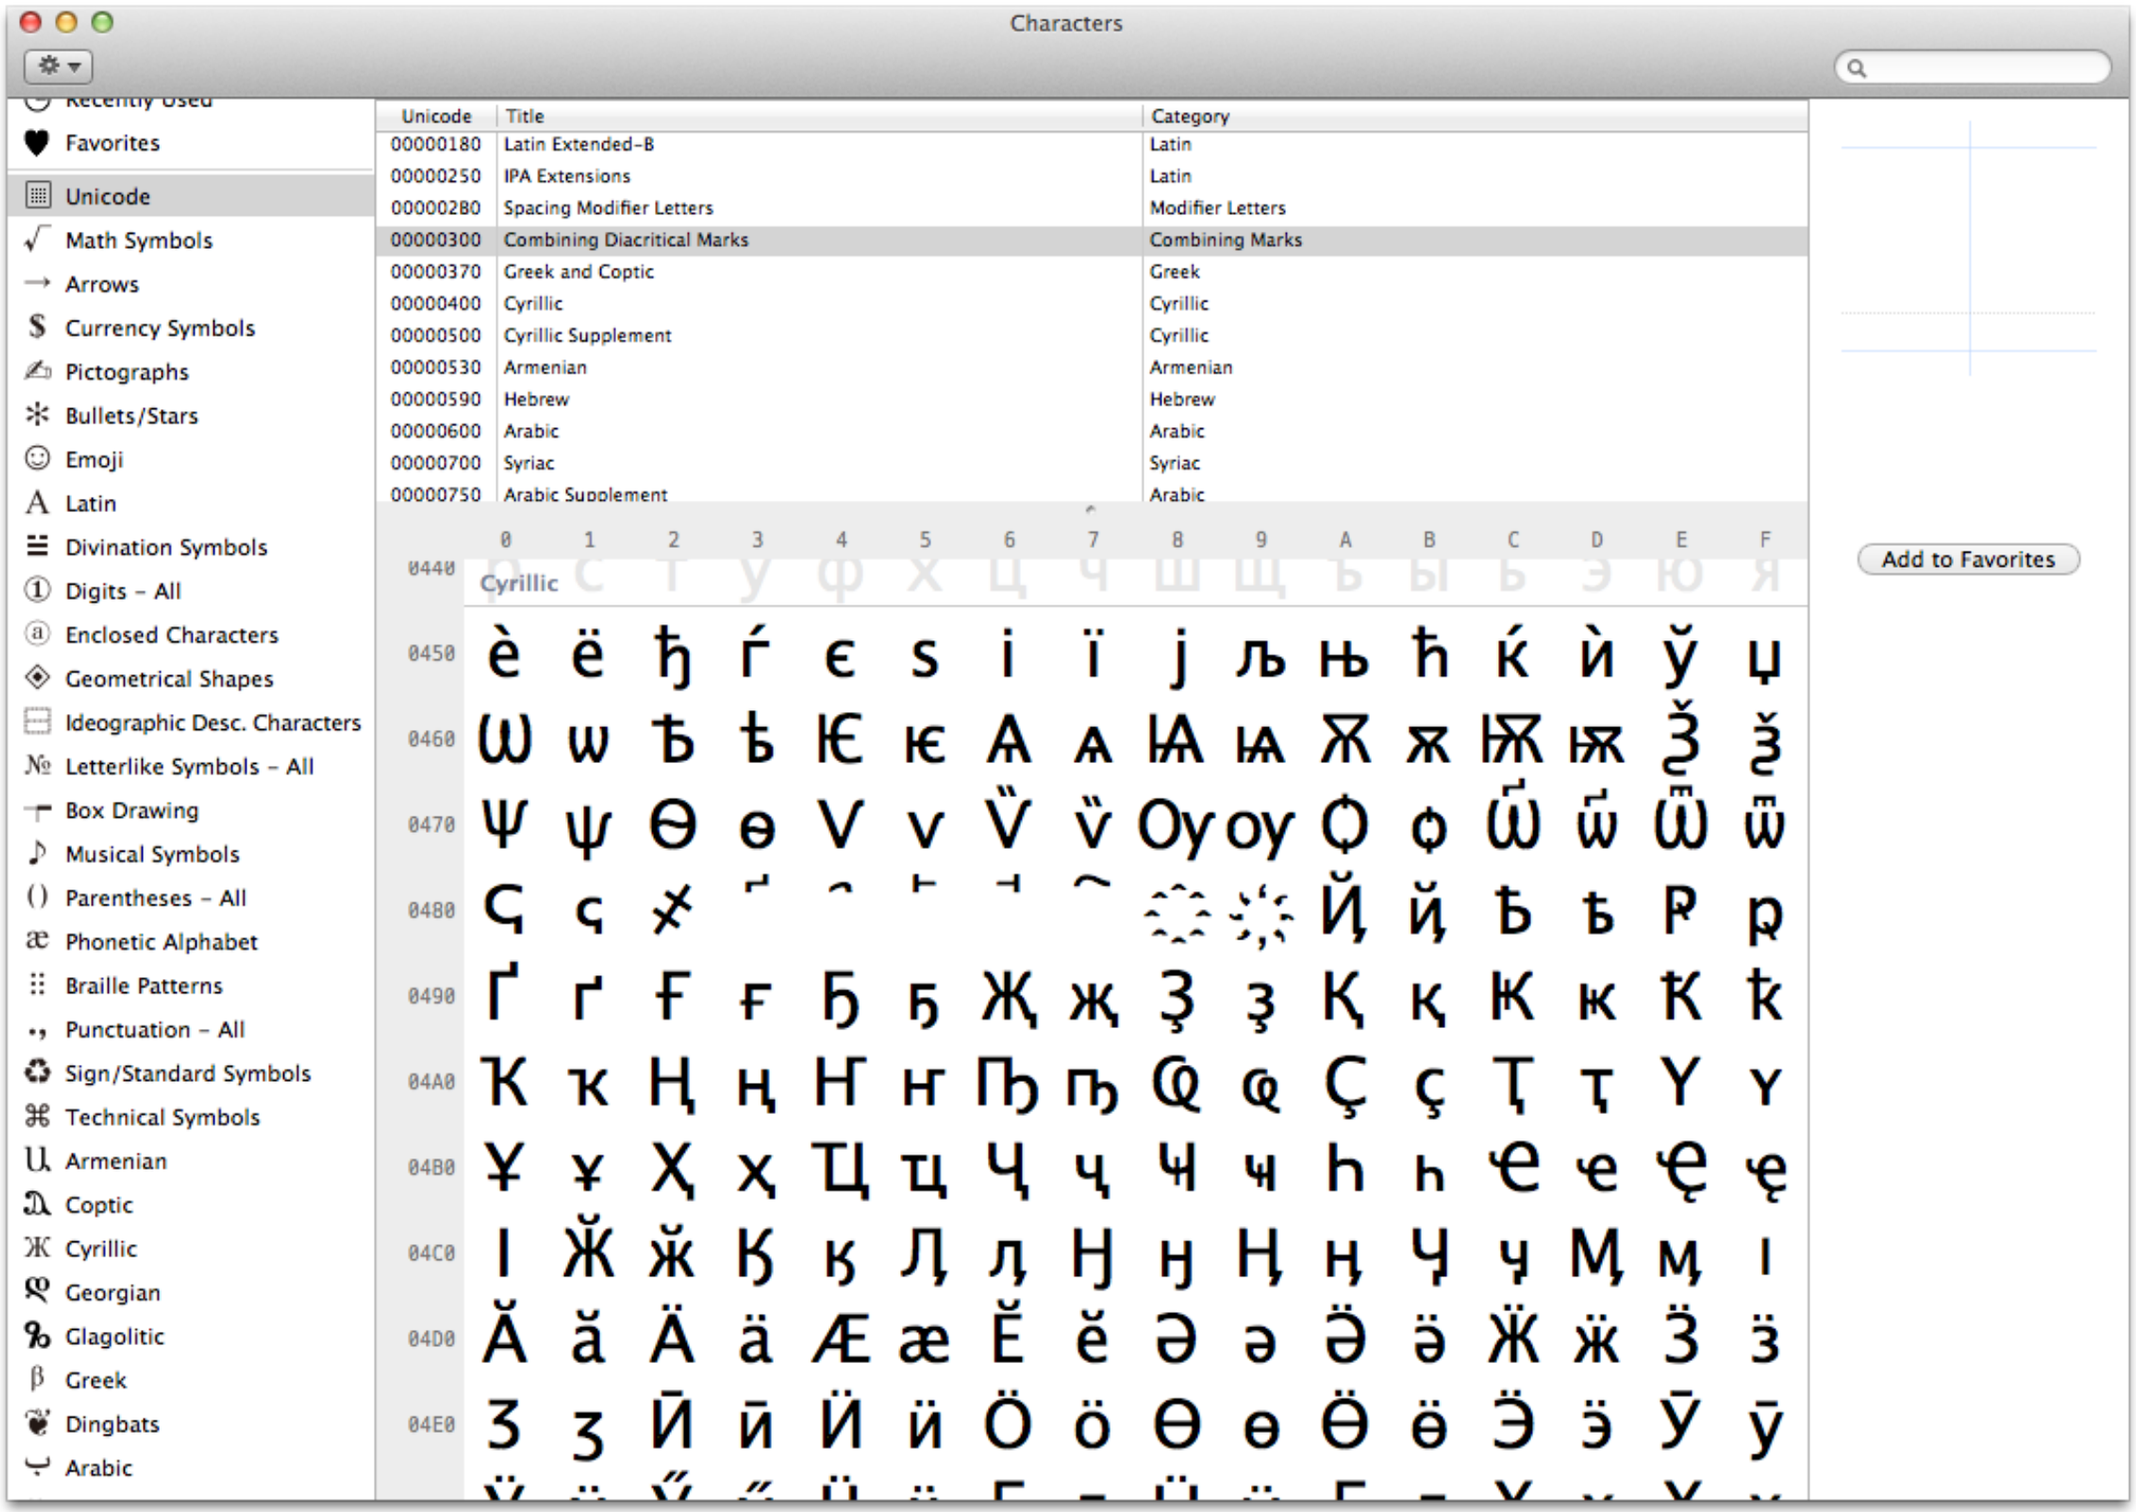

Lire un fichier texte

Démo

```
file = open("movies.txt", "r", encoding="utf-8")
contents = file.read()
file.close()
```

En fait, on n'écrit pas ceci!

Pour être sûr de ne pas oublier le close(), on utilise un *with… as*

On ouvre ce fichier en lecture (*read*)

```
with open("movies.txt", "r", encoding="utf-8") as file:
    contents = file.read()

print(contents)
```

On donne toujours l'encodage à utiliser pour ne pas avoir de surprise

Lecture!

Contient, sous forme de grand string unique, l'intégralité du fichier *movies.txt*

Écrire un fichier texte

Comme pour la lecture, on utiliser un *with… as*, qui fait un *close()* automatique

On ouvre ce fichier en écriture (*write*)

```
with open("results.txt", "w", encoding="utf-8") as file:
    file.write(...)
```

Le travail est fait par la méthode *write(…)*

```
file.write("une ligne\nune autre ligne")
```

Pour écrire plusieurs lignes, on doit indiquer le caractère de nouvelle ligne \n

```
for ...:
    file.write(" ... \n")
```

Si les résultats à écrire sont générés au fur et à mesure, on peut les écrire petit à petit (ici, ligne par ligne) avec des appels répétés de *write()*

Traiter les données lues

- Pour de petits fichiers, on peut tout lire d'un coup…
- … Mais comment traiter le contenu ligne par ligne?
  - Méthode split(), qui sépare une chaîne de caractère en une liste de sous-chaînes
  - Conversions de sous-chaînes en int, en datetime, en bool, etc.
  - Tranformations de chaînes avec tests, split(), replace()
  - Modélisation des données lues avec des classes
- Exemple: lecture du fichier *movies.txt*

Démo

```
Year;Length;Title;Subject;Actor;Actress;Director;Popularity;Awards;*Image
INT;INT;STRING;CAT;CAT;CAT;CAT;INT;BOOL;STRING
1990;111;Tie Me Up! Tie Me Down!;Comedy;Banderas, Antonio;Abril, Victoria;Almodóvar, Pedr
1991;113;High Heels;Comedy;Bosé, Miguel;Abril, Victoria;Almodóvar, Pedro;68;No;NicholasCa
1983;104;Dead Zone, The;Horror;Walken, Christopher;Adams, Brooke;Cronenberg, David;79;No;
1979;122;Cuba;Action;Connery, Sean;Adams, Brooke;Lester, Richard;6;No;seanConnery.png
1978;94;Days of Heaven;Drama;Gere, Richard;Adams, Brooke;Malick, Terrence;14;No;NicholasC
1983;140;Octopussy;Action;Moore, Roger;Adams, Maud;Glen, John;68;No;NicholasCage.png
1984;101;Target Eagle;Action;Connors, Chuck;Adams, Maud;Loma, José Antonio de la;14;No;Ni
1989;99;American Angels: Baptism of Blood, The;Drama;Bergen, Robert D.;Adams, Trudy;Sebas
1985;104;Subway;Drama;Lambert, Christopher;Adjani, Isabelle;Besson, Luc;6;No;NicholasCage
1990;149;Camille Claudel;Drama;Depardieu, Gérard;Adjani, Isabelle;Nuytten, Bruno;32;No;Ni
1982;188;Fanny and Alexander;Drama;Ahlstedt, Börje;Adolphson, Kristina;Bergman, Ingmar;81
```

Lecture et modélisation

```python
from dataclasses import dataclass
from typing import List

with open("movies.txt", "r", encoding="utf-8") as file:
    contents = file.read()
```

Lecture de tout le fichier d'un coup

```python
lines = contents.split("\n")
```

Séparation du contenu de chaque ligne, à chaque apparition du caractère \n

```python
@dataclass
class Movie:
    title: str
    year: int
    duration: int
    has_awards: bool
```

On décide d'une représentation sous de forme de classe pour nos données à traiter

Création des objets depuis le texte lu

```
movies: List[Movie] = []

substitutions = {
    "&": "and",
    "'": "’",
    "vs.": "vs",
}

for line in lines[2:]:
    parts = line.split(";")

    duration_str = parts[1]
    if duration_str == "":
        duration = 0
    else:
        duration = int(duration_str)

    title = parts[2]
    if ", " in title:
        title = " ".join(title.split(", ")[::-1])
    for key, value in substitutions.items():
        title = title.replace(key, value)

    movie = Movie(title, int(parts[0]), duration, parts[8] == "Yes")
    movies.append(movie)
```

On prépare une liste de *Movies*, pour l'instant vide

Les substitutions de caractères qu'on voudra faire dans le titre des films

On saute les deux premières lignes (cf. exemple de contenu)

Chaque ligne est séparée selon les points-virgules qu'elle contient

De temps en temps, la durée est vide… on la met alors à 0. Sinon, on convertit de *str* vers *int*

On «nettoie» le titre, on applique les substitutions

On crée un nouvel objet de type *Movie* et on l'ajoute à la liste

Traitement des données et écriture

```python
def criterion(m: Movie) -> int:
    return m.duration

movies.sort(key=criterion)
```

On trie les films selon un critère de tri donné par ce que cette fonction retourne pour chaque film; ici, sa durée

On prépare un fichier de sortie pour y écrire des résultats

```python
with open("results.txt", "w", encoding="utf-8") as file:
    total_duration = 0

    for movie in movies:
        if movie.has_awards:
            file.write(f"{movie.duration:3} min: “{movie.title}” ({movie.year})\n")
            total_duration += movie.duration

    file.write(f"\nTotal duration: about {total_duration // 60} hours")
```

On y écrit ce qu’on veut: ici, la durée, le titre et l’année des films qui ont reçu un prix, chacun sur une ligne

Dans la boucle, on en a profité pour calculer la durée totale de ces films, qu’on écrit comme ligne finale de ce fichier

Résumé: opérations sur les strings

- Tests
  - Test de longueur, de casse
  - Test de préfixe, suffixe, contenance

```
text = "..."

if len(text) > 20:
if text == text.lower():

if text.startswith("..."):
if text.endswith("..."):
if "..." in text:
```

- Split
  - Sépare un string en une liste selon un délimiteur

```
text = "a,b,c"
parts = text.split(",")
```

- Join
  - Crée un string à partir d'une liste en insérant un délimiteur

```
", ".join(parts)
```

- Replace
  - Rechercher-remplacer

```
new_text = text.replace("a", "A")
```

Pas discuté: les expressions régulières, un moyen très puissant de manipuler du texte

Résumé Cours 12

- Un caractère est représenté par une série de bytes selon un encodage précis
  - Aujourd'hui, UTF-8 est le plus utilisé
- On peut facilement lire et écrire des fichiers texte en Python
  - Nouvelle structure *with*… *as* pour un *close()* automatique
- On peut traiter les données lues avec:
  - Des transformations de strings
  - Des conversions vers d'autres types
  - La construction d'objets via une modélisation par des classes