

Python

niveau avancé

Vincent LE GALLIC

Séminaire Technique du Cr@ns

4 février 2014



Ce séminaire fait suite au [séminaire Python niveau débutant](#)

Modules built-in

Maths et aléa

Temps et dates

Système

Programmation Orientée objet

Introduction

Classes

Surcharge

Héritage

Interaction avec des fichiers

open

json, pickle

Bonus stuff

Nouvelle façon de voir les listes

argparse

re

Modules built-in

Maths et aléa

Temps et dates

Système

Programmation Orientée objet

Introduction

Classes

Surcharge

Héritage

Interaction avec des fichiers

open

json, pickle

Bonus stuff

Nouvelle façon de voir les listes

argparse

re

Fonctions mathématiques

```
import math
```

- ▶ `math.log(x [,base])`, `math.exp(x)`
- ▶ `math.sqrt(x)`
- ▶ `math.cos(x)`, `math.sin(x)`, `math.tan(x)`,
`math.acos(x)`, `math.asin(x)`, `math.atan(x)`
- ▶ Les mêmes avec un `h` à la fin pour les hyperboliques.
- ▶ `math.degrees(r)`, `math.radians(d)` : convertit des radians en degrés et inversement
- ▶ Deux constantes : `math.pi`, `math.e`
- ▶ Doc complète : <http://docs.python.org/2/library/math.html>

Aléatoire

```
import random
```

- ▶ `random.random()` : renvoie un `float` aléatoire dans `[0, 1[`
- ▶ `random.randint(a, b)` : renvoie un entier aléatoire dans `[[a, b]]`
- ▶ `random.choice(l)` : choisit un élément aléatoire dans l'itérable.
- ▶ `random.randrange(start, stop, step)` équivalent à `random.choice(random.randrange(start, stop, step))` (`start` et `step` sont facultatifs)
- ▶ `random.shuffle(l)` : mélange *in place*,
`random.sample(l, k)` : donne `k` éléments choisis aléatoirement dans `l` (sans remise)
- ▶ `random.uniform(a, b)` : retourne un `float` tiré de manière uniforme dans `[a, b]`
- ▶ D'autres lois de répartition : `expovariate`, `gammavariate`, `gauss`, `normalvariate`...
- ▶ Doc complète : <http://docs.python.org/2/library/random.html>

Pseudo-Aléatoire ?

- ▶ `random.seed([x])` : permet d'initialiser le générateur aléatoire. Si `x` n'est pas fourni, le temps système sera utilisé. (Ce seed est effectué à l'import du module.)
- ▶ `random.getstate()`, `random.setstate(state)` : récupère/force l'état interne du générateur aléatoire. Utile pour rejouer les mêmes séquences.
- ▶ Tout ceci est pseudo-aléatoire, avec une seed. On peut générer de l'aléatoire en utilisant `random.SystemRandom`, qui utilisera `os.urandom`, qui se sert des sources d'entropie du système d'exploitation, si disponibles.

Représentation du temps

import time

- ▶ `time.time()` : date actuelle, en secondes depuis l'Epoch¹.
- ▶ `time.localtime([seconds])` : renvoie (année, mois, jour, heure, minute, seconde, `wday`, `yday`, `isdst`) de la timezone locale où `wday` est le numéro du jour dans la semaine (lundi = 0), `yday` le numéro du jour dans l'année (de 1 à 366) et `isdst` le flag Daylight Savings Time. Si `seconds` est fournit, convertit cette durée depuis l'Epoch en 9-tuple.
- ▶ `time.gmtime([seconds])` : même chose mais en temps UTC.
- ▶ `time.mktime(9-tuple)` : convertit un 9-tuple en secondes depuis l'Epoch.
- ▶ `time.clock()` : temps CPU depuis le démarrage de l'interpréteur.

1. 1er Janvier 1970 00h, UTC



- ▶ `time.strftime(format[, 9-tuple])` : Renvoie la date courante (ou celle du tuple) formatée selon `format` : par exemple `"%Y-%m-%d_%H:%M:%S"` (cf man date).
- ▶ `time.strptime(format, string)` : Convertit la chaîne en 9-tuple en utilisant le format.

`import datetime`

- ▶ `datetime.date(year, month, day)` : Créer un objet date.
- ▶ `datetime(year, month, day[, hour[, minute[, second[, microsecond[, tzinfo]]]])` : Créer un objet timestamp.
- ▶ `datetime.timedelta` : Type de la différence entre deux dates.
- ▶ On peut faire la différence entre deux `datetime`, on obtient un `timedelta`, type qu'on peut ajouter à un `datetime`.
- ▶ Un objet `datetime` a une méthode `.strftime(format)`

Intéraction avec le système

import os

- ▶ `os.rename(old, new)`, `os.renamees(old, new)` : **déplace le fichier/dossier.** (`renamees` crée et supprime les dossiers nécessaires.)
- ▶ `os.remove(path)`, `os.rmdir(path)` : **supprime le fichier/le dossier si il est vide.**
- ▶ `os.chdir(path)` : **change le répertoire courant.**
- ▶ `os.umask(mask)` : **changel l'umask en octal (et renvoie le précédent).**
- ▶ `os.chmod(path, mode)`, `os.chown(path, uid, gid)`
- ▶ `os.mkdir(path[, mode])`,
`os.makedirs(path[, mode])` : **crée le/les répertoires.**
- ▶ `os.environ` : **l'environnement du shell, sous forme de dictionnaire.**
- ▶ `os.getcwd()` : **renvoie le chemin absolu du répertoire courant.**



- ▶ `os.getenv(key[, default])`, `os.putenv(key, value)`, `os.unsetenv(key)` : récupère une variable d'environnement / définit ou en modifie une / en supprime une.
- ▶ `os.geteuid()`, `os.getgid()`, `os.getgroups()` : récupère l'uid, le gid principal ou tous les gid de tous les groupe de l'utilisateur courant.
- ▶ `os.getpid()` : obtenir le PID du processus actuel
- ▶ `os.fork()` : dupliquer le processus. Dans le processus fils, la valeur retournée est 0, dans le processus parent, la valeur est le PID du fils.
- ▶ `os.linesep` : contient le séparateur de ligne ("`\n`" sous Linux, "`\r \n`" sous Windows...), utile pour la portabilité.
- ▶ `os.symlink(src, dest)`, `os.readlink(path)` : crée un lien symbolique / lit la destination d'un lien symbolique.



import sys

- ▶ `sys.argv` : La liste des paramètres fournis sur la ligne de commande (avec la commande en `[0]`).
- ▶ `sys.exit([status])` : Quitter (avec éventuellement un code de retour, sinon 0)
- ▶ `sys.getfilesystemencoding()` : Renvoie l'encodage utilisé par le système de fichiers.
- ▶ `sys.getrecursionlimit()`,
`sys.setrecursionlimit(n)` : donne/modifie la profondeur d'appel maximale.
- ▶ `sys.getrefcount(objet)` : donne le nombre de référence vers cet objet python (+1 parce que la fonction elle-même y fait référence).
- ▶ `sys.maxint`, `sys.maxunicode` : contiennent le plus grand `int` et le dernier point de code unicode.



- ▶ `sys.path` : la liste des dossiers dans lesquels l'interpréteur va chercher (dans l'ordre) les modules lorsqu'on fait un **import**.
(ex : `sys.path.insert(0, "/meslib/prioritaires/")`,
`sys.path.append("/usr/scripts/")` ²)
- ▶ `sys.stdin`, `sys.stdout`, `sys.stderr` : Les fichiers d'entrée, de sortie et d'erreur standards liés au tty en cours.

2. Au Cr@ns, on préférera utiliser `#!/bin/bash /usr/scripts/python.sh` qui fait cet ajout une fois pour toutes.

Modules built-in

Maths et aléa

Temps et dates

Système

Programmation Orientée objet

Introduction

Classes

Surcharge

Héritage

Interaction avec des fichiers

open

json, pickle

Bonus stuff

Nouvelle façon de voir les listes

argparse

re

La Programmation Orientée Objet : principe

- ▶ Une **classe** est un *moule* qui permet de créer plusieurs objets (des **instances**) de même type. La classe `Animal` me permet de créer l'instance `pet` :

```
pet = Animal(<paramètres d'initialisation>)
```

- ▶ Les objets ont des **attributs** : `pet.taille_queue`, `pet.cri`. Ils peuvent différer d'une instance à l'autre, et être modifiés (normalement, pas depuis l'extérieur de l'objet).
- ▶ Ils ont également des **méthodes**, fonctions internes à l'objet : `pet.crier()`, `pet.manger(foodsize)`.

La Programmation Orientée Objet : pourquoi ?

- ▶ **Encapsulation** : la définition et le comportement d'un objet sont intérieurs à la classe, le reste du monde n'a à se soucier que de son interface.
- ▶ **Réutilisation du code** : un objet défini une fois peut très bien resservir tel quel dans un autre projet/script/...
- ▶ **DRY**³ : permet d'écrire à un seul endroit des méthodes au lieu de répéter plusieurs fois des fonctions à peine différentes.
- ▶ **Clarté** : **Cet** objet a **ce** comportement, **ces** méthodes. Contrairement à si je trouve une fonction seule, pour laquelle je dois me demander quels objets elle peut/doit prendre en paramètres. (adéquation sémantique/syntaxe)

3. "Don't Repeat Yourself", remember ? Mais vous me faites me répéter...

Définition d'une classe

```
>>> class Chien:
    def __init__(self, poids):
        """Initialiseur"""
        # on stocke le paramètre fourni à l'initialisation dans
        # un attribut de l'objet
        self.poids = poids

    def crier(self):
        print "Ouaf !"

    def manger(self, foodsize):
        self.poids += foodsize

>>> medor = Chien(3)
>>> medor.poids
3
>>> medor.manger(5)
>>> medor.poids
8
>>> medor.crier()
Ouaf !
```




- ▶ Par convention, on nomme les classes en `CamlUpperCase` et les méthodes en `lower_case`.
- ▶ Les méthodes seront toujours appelées avec comme premier paramètre l'objet lui-même. Par convention, on utilise le mot `"self"`, mais on pourrait utiliser autre chose (contrairement au `"this"` Java ou C++).
- ▶ Chaque méthode peut (et devrait) avoir une docstring. La docstring de la méthode `__init__` écrasera celle de la classe.
- ▶ On ne devrait pas toucher aux attributs nous-même (par exemple, faire `pet.poids = 4`), explication slide suivante.

Respect du privé

```
>>> import math
>>> class Vecteur:
    def __init__(self, x, y):
        self.x, self.y = x, y
        self._update_norme()

    def __calculer_norme(self):
        return math.sqrt(self.x**2 + self.y**2)

    def _update_norme(self):
        self.norme = self.__calculer_norme()

    def setcoords(self, newx, newy):
        self.x, self.y = newx, newy
        self._update_norme()

>>> v = Vecteur(3, 4)
>>> v.norme
5.0
>>> v.x = 10
>>> v.norme
5.0
>>> v.setcoords(6, 8)
>>> v.norme
10.0
```

Plus ou moins privé

- ▶ Les méthodes qui commencent par `_` sont par convention privées. Mais Python permet tout de même d'y accéder :

```
>>> v.x, v.y = 9, 12
>>> v._update_norme()
>>> v.norme
15.0
```

- ▶ Les méthodes commençant par `__` mais qui ne finissent pas par `__` sont réellement privées et donc inaccessibles :

```
>>> v.__calculer_norme()
AttributeError: Vecteur instance has no attribute '__calculer_norme'
>>> v._Vecteur__calculer_norme()
15.0
```

En réalité, la méthode est renommée en ajoutant `_ClassName` au début⁴, elle reste *quand même* accessible, mais c'est sale, ne faites pas ça.

4. On appelle ce procédé le **mangling**

Un peu de cosmétique

- ▶ Par défaut, c'est un peu moche :

```
>>> v
<__main__.Vecteur instance at 0x7fc1e42ec5a8>
>>> print v
<__main__.Vecteur instance at 0x7fc1e42ec5a8>
```

- ▶ On peut **surcharger les fonctions spéciales** qui sont appelées dans ces cas-là :

```
>>> class Vecteur:
    [...]
    def __str__(self):
        return "Vecteur de coordonnées (%s, %s)" % (self.x, self.y)

    def __repr__(self):
        return "(%s, %s)" % (self.x, self.y)

>>> v = Vecteur(3, 4)
>>> v
(3, 4)
>>> str(v)
'Vecteur de coordonn\xe3\xa9es (3, 4)'
>>> print v
Vecteur de coordonnées (3, 4)
```

En règle générale, il est déconseillé de surcharger `repr`, et fortement déconseillé de lui faire sortir du non-ASCII.

Surcharge des opérateurs

- ▶ `>>> v + v`
`TypeError: unsupported operand type(s) for +: 'instance' and 'instance'`
- ▶ Une autre fonction spéciale particulièrement utile à surcharger : `__add__`
`>>> Class Vecteur:`
`[...]`
`def __add__(self, v2):`
`return Vecteur(self.x + v2.x, self.y + v2.y)`

`>>> u, v = Vecteur(1,2), Vecteur(3,4)`
`>>> print u + v`
`Vecteur de coordonnées (4, 6)`
- ▶ Le principe est toujours le même : la fonction spéciale (correspondant à l'opérateur) de l'objet de gauche est appelée avec pour paramètre l'objet de droite.
- ▶ On peut prévoir de prendre en paramètre un objet d'un autre type (comme `datetime.datetime` et `datetime.timedelta`).



► Autre exemple, avec `__eq__` :

```
>>> class NonCaseSensitiveString:
    def __init__(self, s):
        self.s = s
    def __str__(self):
        return self.s.__str__()
    def __eq__(self, s2):
        return self.s.lower() == s2.s.lower()

>>> s = NonCaseSensitiveString("CouCou")
>>> t = NonCaseSensitiveString("coUcOu")
>>> s == t
True
```

► Autres fonctions spéciales utiles à connaître :

► `__sub__` : -

► `__div__` : /

► `__mod__` : %

► `__mul__` : *

► `__pow__` : **

► `__neg__` : opposé

► `__cmp__` : renvoie -1 si <, 0 si
==, 1 si >

► `__nonzero__` : résultat de
`x != 0`, utilisé pour la
conversion en booléen

► `__float__` : `float(x)`

► `__int__` : `int(x)`

► `__and__`, `__or__` :
opérations logiques

DRY++ : L'héritage

- On peut factoriser le code en définissant la même méthode pour plusieurs classes.

```
>>> class Animal:
    def __init__(self, poids):
        """Initialiseur"""
        self.poids = poids
    def crier(self):
        print "%s !" % (self.cri)
    def manger(self, foodsize):
        self.poids += foodsize

>>> class Chien(Animal):
    def __init__(self, poids):
        Animal.__init__(self, poids)
        self.cri = "Ouaf"

>>> class Chat(Animal):
    def __init__(self, poids):
        Animal.__init__(self, poids)
        self.cri = "Miaou"

>>> snoopy, felix = Chien(5), Chat(4)
>>> snoopy.manger(2)
>>> felix.manger(2)
>>> snoopy.poids, felix.poids
(7, 6)
>>> snoopy.crier(); felix.crier()
Ouaf !
Miaou !
```

DRY++ : L'héritage

- ▶ On peut factoriser le code en définissant la même méthode pour plusieurs classes.
- ▶ Appeler l'initialiseur du parent n'est pas automatique (et donc pas obligatoire).

```
>>> class Animal:
    def __init__(self, poids):
        """Initialiseur"""
        self.poids = poids
    def crier(self):
        print "%s !" % (self.cri)
    def manger(self, foodsize):
        self.poids += foodsize

>>> class Chien(Animal):
    def __init__(self, poids):
        Animal.__init__(self, poids)
        self.cri = "Ouaf"

>>> class Chat(Animal):
    def __init__(self, poids):
        Animal.__init__(self, poids)
        self.cri = "Miaou"

>>> snoopy, felix = Chien(5), Chat(4)
>>> snoopy.manger(2)
>>> felix.manger(2)
>>> snoopy.poids, felix.poids
(7, 6)
>>> snoopy.crier(); felix.crier()
Ouaf !
Miaou !
```


DRY++ : L'héritage

- ▶ On peut factoriser le code en définissant la même méthode pour plusieurs classes.

- ▶ Appeler l'initialiseur du parent n'est pas automatique (et donc pas obligatoire).

- ▶ On peut écraser une méthode :

```
>>> class Lapin(Animal):
    [...]
    def crier(self):
        raise NotImplementedError
```

```
>>> class Animal:
    def __init__(self, poids):
        """Initialiseur"""
        self.poids = poids
    def crier(self):
        print "%s !" % (self.cri)
    def manger(self, foodsize):
        self.poids += foodsize

>>> class Chien(Animal):
    def __init__(self, poids):
        Animal.__init__(self, poids)
        self.cri = "Ouaf"

>>> class Chat(Animal):
    def __init__(self, poids):
        Animal.__init__(self, poids)
        self.cri = "Miaou"

>>> snoopy, felix = Chien(5), Chat(4)
>>> snoopy.manger(2)
>>> felix.manger(2)
>>> snoopy.poids, felix.poids
(7, 6)
>>> snoopy.crier(); felix.crier()
Ouaf !
Miaou !
```



- ▶ Idéalement, on devrait faire hériter toutes les classes de `object`, afin qu'elles soient des new-style classes. Cela permet un certain nombre de fonctionnalités que n'ont pas les old-style classes :
 - ▶ les properties
 - ▶ les classmethod, staticmethod
 - ▶ le support des métaclasses⁵

Au départ, ces new-style classes ont été créées pour unifier classes et types : `type(x) == x.__class__`, ce qui n'est pas garanti pour les old-style classes. Et accessoirement, en python3, il n'y a plus que les new.

5. pour tout ça, cf séminaire python hardcore

Modules built-in

Maths et aléa

Temps et dates

Système

Programmation Orientée objet

Introduction

Classes

Surcharge

Héritage

Intéraction avec des fichiers

open

json, pickle

Bonus stuff

Nouvelle façon de voir les listes

argparse

re

Lire/Écrire dans un fichier

- Pour écrire du texte dans un fichier :

```
>>> f = open("path/to/file", "w")
>>> f.write("Je mets des choses\ndans mon fichier")
>>> f.close()
```

- Attention, il faut écrire des `str`, donc il faut penser à encoder avant d'éventuels `unicode`.
- Le mode `"w"` signifie qu'on écrase le contenu du fichier. Le mode par défaut est `"r"` (read), il existe également le mode `"a"` (append) pour écrire à la suite du fichier sans écraser ce qui y est déjà. `"w"` et `"a"` créent le fichier si il n'existait pas.
- Pour lire :

```
>>> f = open("path/to/file", "r")
>>> f.read()
'Je mets des choses\ndans mon fichier'
>>> f = open("path/to/file", "r")
>>> f.readlines()
['Je mets des choses\n', 'dans mon fichier']
```

Stockage facile

- ▶ Certains objets peuvent être sérialisés, ce sont None, les strings, nombres et les listes et dictionnaires qui en contiennent.
- ▶ On peut les stocker dans un fichier avec des librairies prévues à cet effet.

```
>>> import json
>>> f = open("store.json", "w")
>>> json.dump({"a" : [3]}, f)
>>> f.close()
>>> f = open("store.json")
>>> json.load(f)
{u'a': [3]}
```

- ▶ Les chaînes sont restituées sous forme d'`unicode` (et devrait aussi être fournis ainsi).
- ▶ L'objet JSON dans le fichier est à peu près human-readable.
- ▶ `pickle` est un autre module qui s'utilise de la même façon. Le format de stockage n'est pas human-readable, cependant.

Modules built-in

Maths et aléa

Temps et dates

Système

Programmation Orientée objet

Introduction

Classes

Surcharge

Héritage

Interaction avec des fichiers

open

json, pickle

Bonus stuff

Nouvelle façon de voir les listes

argparse

re

Listes en compréhension

- ▶ C'est un moyen très "python-esque" de créer des listes, qui est à peu près l'équivalent d'un `map`.

```
>>> l = [2, 2, 5, 10]
>>> l2 = [i**2 for i in l]
>>> l2
[4, 4, 25, 100]
```

- ▶ Il est possible d'imbriquer plusieurs boucles :

```
>>> [a + b for a in "cdf" for b in "aei"]
['ca', 'ce', 'ci', 'da', 'de', 'di', 'fa', 'fe', 'fi']
```

- ▶ On peut également ajouter des conditions (équivalent d'un `filter`) :

```
>>> [a + 1 for a in range(7) if a % 2 == 0]
[1, 3, 5, 7]
```

- ▶ Ça marche aussi avec les dictionnaires⁶ :

```
>>> {i : str(i**2) for i in range(4)}
{0: '0', 1: '1', 2: '4', 3: '9'}
```

6. En 2.7, mais pas en 2.6

Parser les paramètres commandline

► Code :

```
#!/usr/bin/env python
# -*- coding: utf-8 -*-

import argparse

# Déclaration du parseur (noter l'absence de u"")
parser = argparse.ArgumentParser(description="Message d'aide")
parser.add_argument("-v", "--verbose", help="Afficher plus d'infos",
                    action="store_true")
parser.add_argument("-f", "--file", help="Fichier à traiter",
                    action="store", type=str, metavar="Fi")
parser.add_argument("-n", dest="num", help="Numéro de la ligne",
                    action="store", type=int)

# Parsing
print "before parsing"
args = parser.parse_args()
print "after parsing"

# Utilisation des arguments parsés
print "Valeurs : %r, %r, %r" % (args.verbose, args.file, args.num)
```


► Exécution :

```
vincent@eva $ ./test.py -h
before parsing
usage: test.py [-h] [-f Fi] [-n NUM]
```

Message d'aide

optional arguments:

```
-h, --help            show this help message and exit
-v, --verbose         Afficher plus d'infos
-f Fi, --file Fi      Fichier à traiter
-n NUM                Numéro de la ligne
```

```
vincent@eva $ ./test.py -v -f pif -n 6
before parsing
after parsing
Valeurs : True, 'pif', 6
```

```
vincent@eva $ ./test.py -f pif
before parsing
after parsing
Valeurs : False, 'pif', None
```

```
vincent@eva $ ./test.py -f pif -n
before parsing
usage: test.py [-h] [-v] [-f Fi] [-n NUM]
test.py: error: argument -n: expected one argument
```

Parser les paramètres commandline

- ▶ Regarder la doc et les docstrings d'argparse pour voir toutes les possibilités
- ▶ Notamment, `parser.add_mutually_exclusive_group`
- ▶ Il existe également le module `optparse`, moins bien.



Expressions régulières

- ▶ Notion venant de l'info théorique, très utile et utilisée.
- ▶ `perl`, `sed`, `python`, `grep` en ont, mais à chaque fois avec des différences de syntaxe et d'expressivité
- ▶ Un peu de syntaxe des regexp :
 - ▶ `'.'` : Tout sauf `'\n'`⁷
 - ▶ `'^'`/`'$'` : Début/Fin de chaîne⁸
 - ▶ `'(...)'` : Délimite un groupe. Il sera accessible après et référençable dans la regexp elle-même (`'\1'`, `'\2'...`)⁹.
 - ▶ `'*'` : Le précédent groupe, 0 ou plus de fois.
 - ▶ `'+'` : Le précédent groupe, 1 ou plus de fois.
 - ▶ `'?'` : Le précédent groupe, 0 ou 1 fois.
 - ▶ `'{m}'`, `'{m,n}'`, `'{,n}'`, `'{m,}'` Le précédent groupe, respectivement `m` fois exactement, entre `m` et `n` fois, au plus `n` fois, au moins `m` fois.

7. Si DOTALL est activé, matche aussi les newline

8. Si MULTILINE, matche après/avant chaque newline

9. Attention, un groupe peut exister dans d'autres cas : `'a|b'`, `'[a-z]'`

Les regexp en python

- ▶ Le module : `re`
- ▶ Les choses qu'on peut faire avec une regexp :
 - ▶ `match` : vérifier que le motif matche le texte depuis son début
 - ▶ `search` : trouver la première occurrence du motif dans le texte
 - ▶ `findall` : trouver toutes les occurrences disjointes du motif dans le texte, renvoie une liste
 - ▶ `finditer` : presque¹⁰ pareil, mais renvoie un itérateur
 - ▶ `sub` : trouver toutes les occurrences d'une regexp et les remplacer par quelque chose (éventuellement dépendant de ce qui a exactement été matché)
- ▶ Les deux façons de le faire :
 - ▶ `re.<nom_de_la_fonction>(motif, texte)`
 - ▶ `regex = re.compile(motif)`
`regex.<nom_de_la_fonction>(texte)`

Cette méthode permet de rajouter le paramètre
`flags=re.UN_FLAG`

10. Renvoie des match objects et non pas le résultat de `.groups()`

Regex : pratique

- Simple matching (vérifier si un truc matche une regexp) :

```
>>> import re
>>> re.match('ab+c', 'abbc')
<_sre.SRE_Match at 0x2cf9780>
>>> re.match('ab+c', 'abbc d')
<_sre.SRE_Match at 0x2cf9ac0>
>>> re.match('ab+c', 'acd')
```

- Accès aux groupes :

```
>>> match = re.match(' (a{2,}) (b+)k (c?)', 'aaabkd')
>>> match.group()
'aaabk'
>>> match.groups()
('aaa', 'bk', 'b', '')
```

Les escape sequences

Elles permettent de matcher plus de choses :

- ▶ `'*', '\?', '\$' ...` : pour matcher les caractères spéciaux (désactiver leur comportement)
- ▶ `'\1', ..., '\99'` : matche les groupes dans l'ordre
- ▶ `'\s'` : matche les whitespace, équivalent à `'[\t \n \r \f \v]'` si le flag UNICODE est inactif, si il est actif, matche tout caractère espace (notamment les espaces insécables)
- ▶ `'\S'` : matche tout non-whitespace
- ▶ `'\d'` : matche tout digit, équivalent à `'[0-9]'`, plus si UNICODE
- ▶ `'\D'` : matche tout non-digit
- ▶ ...
- ▶ Voir la [liste complète dans la doc](#)

Les flags

On peut modifier le comportement avec un ou plusieurs flags :

```
>>> text = "ala\na3"
>>> r = re.compile("a.")
>>> r.findall(text)
['a1', 'a3']
>>> r = re.compile("a.", flags=re.DOTALL)
>>> r.findall(text)
['a1', 'a\n', 'a3']
```

- ▶ **DEBUG** : affiche les informations sur la regexp au moment de sa compilation
- ▶ **IGNORECASE** : rend la regexp insensible à la casse
- ▶ **MULTILINE** : `'^'` et `'$'` matchent en début et fin de chaque ligne
- ▶ **DOTALL** : `'.'` matche aussi un `'\n'`
- ▶ **UNICODE** : change le comportement de certaines escape-sequences. Par exemple, `'é'` sera considéré comme un caractère alphanumérique et l'espace insécable sera matché par `'\s'`

Pour utiliser plusieurs flags, on les additionne.



Plus de syntaxe des regexp

- ▶ `'|'` : "Ou" entre deux groupes : `'(aa|bb)'` matche `'aa'` et `'bb'`. Attention, `'aa|bb'` matche `'aab'` et `'abb'`.
- ▶ `'[...]'` : Ensemble (set) de caractères
 - ▶ Un "ou++" : `'[abcd]'`
 - ▶ Range : `'[a-zA-Z]'` (`'\-'` ou en début/fin de set pour un vrai tiret)
 - ▶ Les caractères spéciaux perdent leur sens : `'[(+*)]'` matche un de ces caractères
 - ▶ On peut demander le complémentaire d'un set : `'[^a-z]'`
 - ▶ Pour inclure un `']'` dans un set, l'échapper à coup de backslash, ou le mettre au début : `'[a\\b]'`, `'[]ab]'`
- ▶ Groupe spéciaux
 - ▶ `'(?:...)'` : groupe non-capturant. Ne sera pas affiché par `.groups()` et ne peut pas être référencé par `'\1'...`
 - ▶ `'(?iLmsux)'` : activer un ou des flags. C'est une alternative à la méthode consistant à les déclarer dans le `re.compile`.
 - ▶ `'(?P<nom>...)'` : groupe capturant et nommé. On peut le référencer par son numéro ou par `'(?P=nom)'`. Apparaîtra dans `match.groupdict()`.

Quelques astuces supplémentaires

► Application, avec `urllib` en bonus :

```
>>> url = "https://wiki.crans.org/VieBde/PlanningSoirees/LeCalendrier"
>>> url += "?action=raw"
>>> texte = urllib.urlopen(url).read()
>>> regex = "(?:start|end):: (?P<date>[-0-9]+) (?P<heure>[0-9:]+) "
>>> [m.groupdict() for m in re.finditer(regex, texte)]
[{'date': '2015-03-28', 'heure': '00:00'},
 {'date': '2015-03-29', 'heure': '23:59'},
 ...
 {'date': '2008-03-06', 'heure': '14:00'}]
```

► Attention, les multiplicateurs sont par défaut gloutons

(= matchent la plus longue chaîne possible).

Alternative non-gloutonne : `'*?'`, `'+?'`, `'??'`, `'{m,n}?'`

```
>>> re.match('<.*>', '<h1>Title</h1>').group()
'<h1>Title</h1>'
>>> re.match('<.*?>', '<h1>Title</h1>').group()
'<h1>'
```