Text Processing in Python

Text Processing in Python

- Python è un linguaggio molto potente per la manipolazione e la gestione di informazioni testuali
- In questa lezione:
  - Ripassi e approfondimenti sulle **stringhe:** semplici operazioni sul testo
  - **Espressioni regolari**: un potente strumento di text processing, anche in Python

Rappresentazione di stringhe

- Ogni stringa è memorizzata nella memoria del calcolatore come una lista di caratteri
  - >>> myString = “GATTACA”

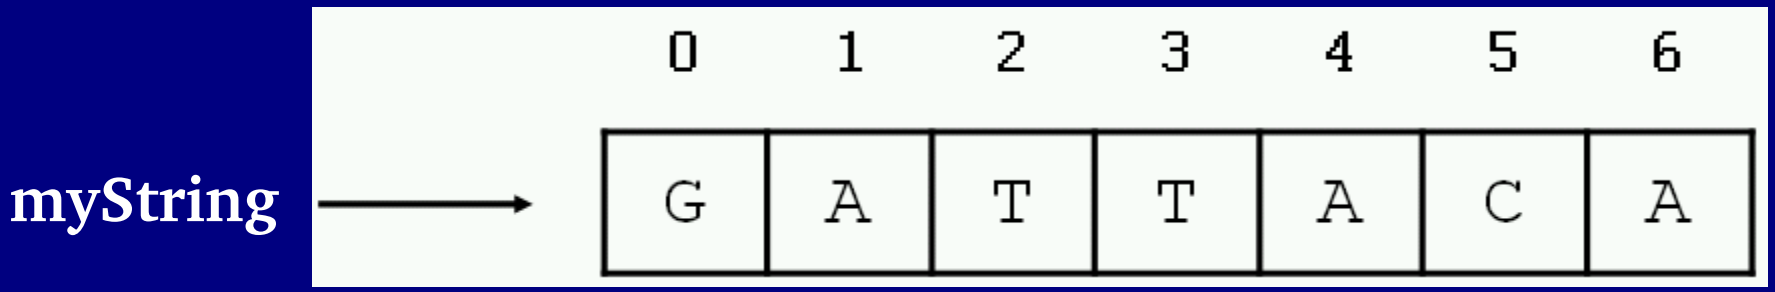

Accesso ai singoli caratteri

- E' possibile accedere ai singoli caratteri utilizzando gli indici tra parenteisi quadre

```
>>> myString = "GATTACA"
>>> myString[0]
'G'
>>> myString[1]
'A'
>>> myString[-1]
'A'
>>> myString[-2]
'C'
>>> myString[7]
Traceback (most recent call last):
  File "<stdin>", line 1, in ?
IndexError: string index out of range
```

Gli indici negativi iniziano dalla fine della stringa e crescono verso sinistra

Accesso alle sottostringhe

```
>>> myString = “GATTACA”
>>> myString[1:3]
‘AT’
>>> myString[:3]
‘GAT’
>>> myString[4:]
‘ACA’
>>> myString[3:5]
‘TA’
>>> myString[:]
‘GATTACA’
```

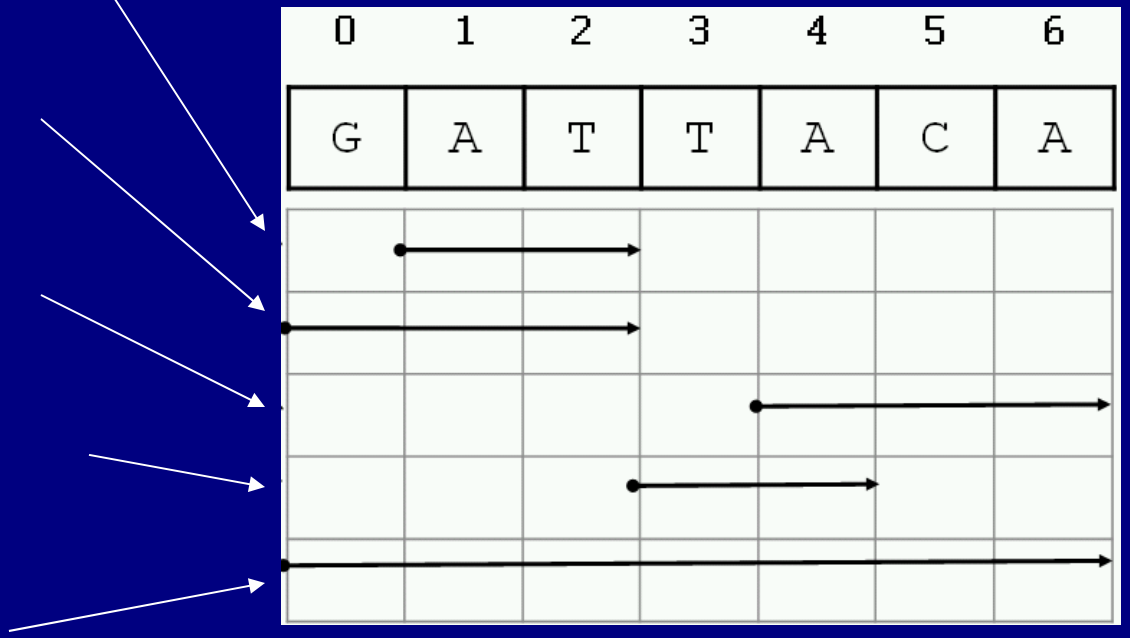

Caratteri speciali

- **Per introdurre un carattere speciale si utilizza il backslash**

```
>>> "He said, "Wow!""
  File "<stdin>", line 1
    "He said, "Wow!""
                  ^
SyntaxError: invalid syntax
>>> "He said, 'Wow!'"
"He said, 'Wow!'"
>>> "He said, \"Wow!\""
'He said, "Wow!"'
```

Sequenza di escape	Significato
\\	Backslash
\'	Single quote
\"	Double quote
\n	Newline
\t	Tab

Alcuni operatori utili

```
>>> len("GATTACA")
7
>>> "GAT" + "TACA"
'GATTACA'
>>> "A" * 10
'AAAAAAAAAA
>>> "GAT" in "GATTACA"
True
>>> "AGT" in "GATTACA"
False
```

← Lunghezza

← Concatenazione

← Ripetizione

← Test di sottostringa

Alcuni esempi di metodi stringa

- ESEMPI: string.py

```
>>> "GATTACA".find("ATT")
1
>>> "GATTACA".count("T")
2
>>> "GATTACA".lower()
'gattaca'
>>> "gattaca".upper()
'GATTACA'
>>> "GATTACA".replace("G", "U")
'UATTACA‘
>>> "GATTACA".replace("C", "U")
'GATTAUA'
>>> "GATTACA".replace("AT", "**")
'G**TACA'
>>> "GATTACA".startswith("G")
True
>>> "GATTACA".startswith("g")
False
```

Split e join

- ESEMPI: splitjoin.py

- Il metodo split() è utilizzato per suddividere una stringa in una sequenza di elementi

```
>>> '1+2+3+4+5'.split('+')
['1', '2', '3', '4', '5']
>>> 'Using the default'.split()
['Using', 'the', 'default']
```

- Il metodo join() è utilizzato per unire una sequenza di stringhe

```
>>> seq = ['1', '2', '3', '4', '5']
>>> sep = '+'
>>> sep.join(seq)
'1+2+3+4+5'
```

strip

- Il metodo strip (s[, chars]) restituisce una copia della stringa con i caratteri iniziali e finali rimossi
  - Se chars non è specificato, vengono rimossi gli spazi bianchi (tab, spazio)
  - Utile per “ripulire” le stringhe

```
>>> '   spacious   '.strip()
'spacious’
>>> 'www.example.com'.strip('cmowz.')
'example'
```

Le stringhe sono immutabili

- Attenzione: le stringhe non possono essere modificate
- Per la modifica è necessario crearne di nuove

```
>>> s = "GATTACA"
>>> s[3] = "C"
Traceback (most recent call last):
  File "<stdin>", line 1, in ?
TypeError: object doesn't support item assignment
>>> s = s[:3] + "C" + s[4:]
>>> s
'GATCACA'
>>> s = s.replace("G","U")
>>> s
'UATCACA'
```

Le stringhe sono immutabili

- Attenzione: i metodi stringa non modificano la stringa, ma ne restituiscono una nuova

```
>>> sequence = “ACGT”
>>> sequence.replace(“A”, “G”)
‘GCGT’
>>> print sequence
ACGT

>>> sequence = “ACGT”
>>> new_sequence = sequence.replace(“A”, “G”)
>>> print new_sequence
GCGT
```

Espressioni regolari

- Le espressioni regolari sono un potente mezzo di elaborazione del testo
- Python include un ricco pacchetto per la gestione di espressioni regolari: **re**
  - Gestione delle espressioni in stile Perl
  - Creazione di un oggetto rappresentante l'espressione regolare
  - Invocazione di metodi per il match di espressioni regolari su stringa

Sintassi di base

- Una stringa di testo regolare fa match con se stessa
  - “test” fa match in “Questo è un test”
- “.” fa match con ogni carattere singolo
- x* fa match con zero o più x
  - “a*” fa match con ”, ’a’, ’aa’, etc.
- x+ fa match con una o più x
  - “a+” fa match con ’a’,’aa’,’aaa’, etc.
- x? fa match con zero o una x
  - “a?” fa match con ” o ’a’
- x{m, n} fa match con i x, dove m < i < n
  - “a{2,3}” fa match con ’aa’ o ’aaa’

Sintassi di base

- [x] fa match con un qualunque carattere della lista x
  - "[abc]" fa match con 'a','b' o 'c'
- [^x] fa match con un qualunque carattere non incluso in x
  - "[^abc]" fa match con qualunque carattere eccetto 'a','b',o 'c'
- Le parentesi () sono utilizzate per i gruppi
  - "(abc)+" fa match con 'abc', 'abcabc', 'abcabcabc', etc.
- x|y fa match con x o y
  - "this|that" fa match con 'this' e 'that', ma non 'thisthat'.

Sintassi di base

- “\d” fa match con una cifra
- “\D” fa match con una non-cifra
- “\s” fa match con un carattere whitespace
- “\S” fa match con un carattere non-whitespace
- “\w” fa match con un carattere alfanumerico
- “\W” fa match con un carattere non alfanumerico
- “^” fa match con l’inizio della stringa
- “$” fa match con la fine della stringa
- “\b” fa match con un word boundary
- “\B” fa match con una posizione che non è un word boundary

Escaping di caratteri speciali

- Attenzione ai caratteri speciali!
  - 'python.org' fa match con 'python.org' ma anche con 'pythonzorg', etc.
- Per fare in modo che un carattere speciale si comporti da carattere normale, occorre farne l'escaping (carattere di backslash anteposto):
  - 'python\\.org' fa match con 'python.org'
- Attenzione al doppio backslash (non singolo)!
  - Nelle stringhe normali, ogni backslash viene valutato
  - Per far arrivare al modulo re la stringa corretta (python\\.org) occorre annullare il primo backslash

Escaping di caratteri speciali

- Per quanto riguarda gli insiemi di caratteri, l'escaping è possibile ma non necessario
- Attenzione però ai seguenti casi:
  - E' necessario l'escaping di ^ se compare all'inizio del set e non si vuole intenderlo come operatore di negazione.
  - Analogamente,] e - devono essere posti all'inizio del set oppure deve esserne fatto l'escaping

Stringhe “raw”

- Una pratica alternativa all’escaping all’interno di stringhe è di utilizzare le raw string
- Una stringa raw non è soggetta ad escaping
- Una stringa raw ha una r anteposta
  - ‘Questa è una stringa’
  - r‘Questa è una stringa raw’
- Differenze con le stringhe normali

```
>>> print 'C:\\nowhere’
C:\nowhere
```

- Con una stringa raw:

```
>>> print r'C:\nowhere’
C:\nowhere
```

Esempi di utilizzo di stringhe “raw”

- Supponiamo di voler scrivere una RE che indichi le corrispondenze della stringa "\section", tipico comando LATEX
- Senza utilizzare stringhe raw, dovremmo seguire i seguenti passi:
  - \section — Stringa di testo di cui cercare la corrispondenza
  - \\section — Annullamento del backslash per il modulo re
  - "\\\\section" — Annullamento del backslash nella stringa normale

Esempi di utilizzo di stringhe “raw”

- utilizzando stringhe raw, l'esempio precedente si riduce a:
  - \section Stringa di testo di cui cercare la corrispondenza
  - \\section Annullamento del backslash per il modulo re
- r'\\section' Uso della stringa raw

modulo re: alcune funzioni importanti

- search(pattern, string[, flags])
  - Effettua la ricerca di pattern in string
- match(pattern, string[, flags])
  - Fa match con pattern all'inizio di string
- split(pattern, string[, maxsplit=0])
  - Suddivide string in base alle occorrenze di pattern
- findall(pattern, string)
  - Restituisce una lista di tutte le occorrenze di pattern in string

modulo re: alcune funzioni importanti

- sub(pat, repl, string[, count=0])
  - Sostituisce con repl tutte le occorrenze di pat in string
- compile(pattern[, flags])
  - Crea un oggetto pattern da una stringa con una regexp
- escape(string)
  - Effettua l'escaping di tutti i caratteri speciali di string

Search e Match

- I due metodi principali sono re.search() e re.match()
  - re.search() ricerca un pattern ovunque nella stringa
  - re.match() effettua la ricerca solo a partire dall'inizio della stringa
- Tali metodi restituiscono None se il pattern non è trovato e un "match object" se lo è

```
>>> pat = "a*b"
>>> import re
>>> re.search(pat,"fooaaabcde")
<_sre.SRE_Match object at 0x809c0>
>>> re.match(pat,"fooaaabcde")
>>>
```

Gruppi

- Il pattern seguente fa match con alcuni comuni indirizzi email:
  - \w+@(\w+\.)+(com|org|net|edu)

```
>>> pat1 = "\w+@(\w+\.)+(com|org|net|edu)"
>>> r1 = re.match(pat,"finin@cs.umbc.edu")
>>> r1.group()
'finin@cs.umbc.edu’
```

- Potremmo voler fare match con sotto-parti del pattern, come il nome email e l’host

Gruppi

- ESEMPI: match.py

- E’ sufficiente racchiudere tra parentesi i “gruppi” che vogliamo identificare

```
>>> pat2 = "(\w+)@((\w+\.)+(com|org|net|edu))"
>>> r2 = re.match(pat2,"finin@cs.umbc.edu")
>>> r2.group(1)
'finin'
>>> r2.group(2)
'cs.umbc.edu'
>>> r2.groups()
r2.groups()
('finin', 'cs.umbc.edu', 'umbc.', 'edu’)
```

Gruppi

- ESEMPI: namedgroup.py

- Notare che i gruppi sono numerati in pre-ordine (cioè rispetto alla loro parentesi di apertura)
- È anche possibile etichettare i gruppi e referenziarli attraverso le etichette

```
>>> pat3 ="(?P<name>\w+)@(?P<host>(\w+\.)+(com|org|
net|edu))"
>>> r3 = re.match(pat3,"finin@cs.umbc.edu")
>>> r3.group('name')
'finin'
>>> r3.group('host')
'cs.umbc.edu’
```

Cos'è un match object?

- Il match object è un'istanza della classe match con i dettagli del risultato del match
- >>> pat = "a*b"
- >>> r1 = re.search(pat,"fooaaabcde")
- >>> r1.group() # restituisce la stringa che ha fatto match
- 'aaab'
- >>> r1.start() # indice dell'inizio del match
- 3
- >>> r1.end()   # indice della fine del match
- 7
- >>> r1.span()   # tupla (start, end)
- (3, 7)

re match object: Alcuni metodi utili

- group([group1, ...])
  - Restituisce le occorrenze dei sotto-pattern(gruppi)
- start([group])
  - Restituisce la posizione di inizio dell'occorrenza di un dato gruppo
- end([group])
  - Restituisce la posizione di fine dell'occorrenza di un dato gruppo
- span([group])
  - Restituisce le posizioni di inizio e fine

re.split()

ESEMPI: resplit.py

- re.split() è simile a split() ma può utilizzare dei pattern

```
>>> some_text = 'alpha, beta,,,,gamma  delta’
>>> re.split('[, ]+', some_text)
['alpha', 'beta', 'gamma', 'delta']
```

- Con il parametro maxsplit è anche possibile indicare il massimo consentito numero di suddivisioni

```
>>> re.split('[, ]+', some_text, maxsplit=2)
['alpha', 'beta', 'gamma  delta’]
>>> re.split('[, ]+', some_text, maxsplit=1)
['alpha', 'beta,,,,gamma  delta']
```

Altre funzioni del modulo re

- re.findall() trova tutti i match:

```
>>> re.findall("\d+”,"12 dogs,11 cats, 1 egg")
['12', '11', ’1’]
```

- re.sub() sostituisce un pattern con una stringa specificata

```
>>> re.sub('(blue|white|red)', 'black', 'blue socks and red shoes')
'black socks and black shoes’
```

sub e i gruppi

- È possibile compiere sostituzioni avanzate utilizzando re.sub() insieme a riferimenti a gruppi
- Ad esempio, immaginiamo di voler sostituire '*something*' con 'something’:
- >>> emphasis_pattern = r'*([^*]+)*’
- >>> re.sub(emphasis_pattern, r'\1', 'Hello, *world*!')
- 'Hello, world!’

sub e le funzioni di sostituzione

- È possibile compiere sostituzioni avanzate utilizzando vere e proprie funzioni di sostituzione invece che una semplice stringa

```
def dashrepl(matchobj):
        if matchobj.group(0) == '-':
            return ' ’
        else:
            return '-’
>>>re.sub('-{1,2}', dashrepl, 'pro----gram-files')
'pro--gram files'
```

Pattern greedy e non greedy

- ATTENZIONE: gli operatori di ripetizione sono greedy (ingordi) di default, cioè tentano di trovare i match più grandi possibili
- Questo può a volte produrre risultati non desiderati

```
>>> emphasis_pattern = r'\*(.+)\*’
>>> re.sub(emphasis_pattern, r'<em>\1</em>',
'*This* is *it*!’)
'<em>This* is *it</em>!’
```

Pattern greedy e non greedy

- Per risolvere il problema, è sufficiente utilizzare le versioni non-greedy degli operatori di ripetizione, ad es:
  - + operatore greedy
  - +? operatore non-greedy

```
>>> emphasis_pattern = r'\*(.+?)\*'
>>> re.sub(emphasis_pattern, r'<em>\1</em>', '*This* is *it*!')
'<em>This</em> is <em>it</em>!'
```

Compilazione di espressioni regolari

- Se si prevede di utilizzare un pattern re più di una volta, è consigliabile compilarlo, ottenendo un oggetto pattern
- Python produce in questo caso una speciale struttura dati che ne velocizza il matching

```
>>> cpat = re.compile(pat)
>>> cpat
<_sre.SRE_Pattern object at 0x2d9c0>
>>> r = cpat.search("finin@cs.umbc.edu")
>>> r
<_sre.SRE_Match object at 0x895a0>
>>> r.group()
'finin@cs.umbc.edu'
```

Pattern object: metodi

- Per un pattern object sono definiti metodi analoghi a quelli visti nel modulo re:
  - match
  - search
  - split
  - findall
  - sub
-

Generatori

- ESEMPI: generators.py

- Un generatore è una funzione che produce una sequenza di risultati invece di un singolo valore
- I valori della sequenza sono ritornati uno alla volta, tramite l'istruzione yield

```
def countdown(n):
    while n > 0:
        yield n
        n-=1
>>> for i in countdown(5):
...         print i,
...
5 4 3 2 1
>>>
```

Generatori

- Il comportamento di un generatore è diverso da quello di una normale funzione
- L'invocazione di un generatore produce un oggetto generatore
- NON esegue la funzione!

```
def countdown(n):
    print “Counting down from”, n
    while n > 0:
        yield n
        n-=1
>>> x = countdown(10)
>>> x
<generator object at “hex. Address”>
>>>
```

Notate come non sia stampato alcun valore

Generatori

- La funzione viene eseguita invocando il metodo next() dell'oggetto generatore
  - Un po' come avviene per gli iteratori

```
>>> x = countdown(10)
>>> x
<generator object at “hex. Address”>
>>> x.next()
Counting down from 10
>>>
```

La funzione inizia la sua esecuzione qui

- yield produce un valore e sospende la funzione fino alla prossima next()

```
>>> x.next()
9
>>> x.next()
8
```

Generatori

- Quanto la funzione ritorna, l'iterazione finisce

```
>>> x.next()
1
>>> x.next()
Traceback (most recent call last):
    File “<stdin>”, line 1, in ?
StopIteration
```

La funzione inizia la sua esecuzione qui

Generatori vs. Iteratori

- Un oggetto generatore è diverso da un oggetto iteratore
- Il generatore è il classico esempio di one-time operation
  - L'iterazione avviene una sola volta
  - Se si vuole ripetere l'iterazione, è necessario creare un altro generatore
  - Un iteratore può iterare su una lista quante volte vuole
- Il generatore è più semplice da usare
  - Non occorre creare i metodi .next(), .__iter__(), etc.

Espressioni generatrici

- ESEMPI: genlog.py

- È possibile creare sequenze in maniera simile alle list comprehension
- List comprehension: lista creata tramite un ciclo for

```
>>> fruit = [ 'apple ', ' orange ', ' pear   ']
>>> list = [ f.strip() for f in fruit]
['apple', 'orange', 'pear']
>>>
```

- Esempio di espressione generatrice

```
>>> a = [1, 2, 3, 4]
>>> b = (2*x for x in a)
>>> b
<generator object at “hex address”>
>>> for i in b: print i,
2 4 6 8
```