

Obsah dnešnej prednasky

1. Iterator a generator

2. Lenive vyhodnocovanie (Lazy evaluation)

Iterator a Generator

inspirovane http://www.python-course.eu/python3_generators.php (http://www.python-course.eu/python3_generators.php)

Iterator

- je objekt, ktorý má funkciu `__next__` a funkciu `__iter__`, ktorá vracia `self`
- je to všeobecnejší pojem ako generator
- dá sa používať na iterovanie cez kolekciu bez toho, aby sme vedeli, ako je jej vnútorná štruktúra. Stačí definovať funkciu `__next__`. Podobný koncept sa dá nájsť vo veľa jazykoch. Napríklad aj v Jave.

Iterator sa napríklad implicitne používa pri prechádzaní kolekcie for cyklom

```
In [ ]: cities = ["Paris", "Berlin", "Hamburg", "Frankfurt", "London", "Vienna", "Amsterdam", "Den Haag"]
for location in cities:
    print("location: " + location)
```

```
In [ ]: dir(cities.__iter__())
```

```
In [ ]: print(type(cities.__iter__()))
print(type(cities.__iter__().__iter__()))
print(cities.__iter__().__next__())
```

Rovnako sa používajú iterátory aj pri prechádzaní iných kolekcii

```
In [ ]: capitals = { "France": "Paris", "Netherlands": "Amsterdam", "Germany": "Berlin", "Switzerland": "Bern", "Austria": "Vienna" }
for country in capitals:
    print("The capital city of " + country + " is " + capitals[country])
```

Generator

- každý generator objekt je iterator, ale nie naopak
- tento pojem sa používa na pomenovanie funkcie (generator funkcia) ako aj jej navratovej hodnoty (generator objekt)
- generator objekt sa vytvára volaním funkcie (generator funkcie), ktorá používa `yield`

Generator používa výraz `yield` na zastavenie vykonávania a na vrátenie hodnoty

- Vykonávanie sa spúšťa volaním funkcie `next()` (alebo metódy `__next__()`)
- Ďalšie volanie začína od posledného `yield`
- Medzi volaniami sa hodnoty lokálnych premenných uchovávajú.

Pozor, toto nie je ten istý `yield` ako je v Ruby

- V Ruby je `yield` volanie bloku asociovaného s metódou
- V Ruby je niečo podobné generatorom napríklad trieda `Enumerator`

<http://stackoverflow.com/questions/2504494/are-there-something-like-python-generators-in-ruby> (<http://stackoverflow.com/questions/2504494/are-there-something-like-python-generators-in-ruby>).

```
In [ ]: def city_generator():
        yield "Konstanz"
        yield "Zurich"
        yield "Schaffhausen"
        yield "Stuttgart"
```

```
In [ ]: gen = city_generator()
```

```
In [ ]: next(gen)
```

Vo vnútri generator funkcie mozem pouzivat cyklus

```
In [ ]: cities = ["Konstanz", "Zurich", "Schaffhausen", "Stuttgart"]
        def city_generator():
            for city in cities:
                yield city
        gen = city_generator()
```

```
In [ ]: next(gen)
```

Tento generátor vlastne len supljuje iterator, ktorý je nad polom, ale ten cyklus môže robiť aj niečo viac a vtedy to už môže byť zaujímavejšie (ukážem neskôr)

Generator funkcia môže prijať parametre

```
In [ ]: def city_generator(local_cities):
        for city in local_cities:
            yield city
        gen = city_generator(["Konstanz", "Zurich", "Schaffhausen", "Stuttgart"])
```

```
In [ ]: next(gen)
```

Trik ako napísať generator, ktorý veľmi často funguje

Uloha: Máme sekvenciu čísel a chceme vytvoriť pohyblivý priemer dvoch po sebe nasledujúcich čísel pre celú sekvenciu.

napr:

sekvencie = [1,2,3,4,5]

phylivny priemer = [(0+1)/2, (1+2)/2, (2+3)/2, (3+4)/2, (4+5)/2] = [0.5, 1.5, 2.5, 3.5, 4.5]

Ako by ste to napísali imperatívne ak to chcete len zapísať do konzoly?

```
In [ ]: sequence = [1,2,3,4,5]
        previous = 0
        for actual in sequence:
            print((actual + previous) / 2)
            previous = actual
```

Zabalím to do funkcie

```
In [ ]: sequence = [1,2,3,4,5]
        def moving_average(sequence):
            previous = 0
            for actual in sequence:
                print((actual + previous) * 0.5)
                previous = actual
        moving_average(sequence)
```

Vymenim print za yield

```
In [ ]: sequence = [1,2,3,4,5]
def moving_average(sequence):
    previous = 0
    for actual in sequence:
        yield (actual + previous) * 0.5
        previous = actual
```

```
In [ ]: print(list(moving_average(sequence)))
```

Pomocou generatoru by sa dala napriklad spravit funkcia map

```
In [ ]: def map(f, seq):
        for x in seq:
            print(f(x))
```

```
In [ ]: def map(f, seq):
        for x in seq:
            yield f(x)
```

Porovnajte si ako by vyzerala implementacia map v python2 a python3

```
In [ ]: def map(f, seq): # V pythone 2 map vracia List, implementacia by mohla byt napriklad takato
        result = [] # mame premennu, ktoru postupne upravujeme a nafukujeme
        for x in seq:
            result.append(f(x))
        return result
```

```
In [ ]: def map(f, seq): # V pythone 3 map je generator a zabera konstantne mnozstvo pamati
        for x in seq:
            yield f(x)
```

Niektore generatory sa daju nahradit funkciou map

```
In [ ]: a, b = 1, 10
def squares(start, stop):
    for i in range(start, stop):
        yield i * i

generator = squares(a, b)
print(generator)
print(next(generator))
print(list(generator))
```

```
In [ ]: generator = map(lambda i: i*i, range(a, b))
print(generator)
print(next(generator))
print(list(generator))
```

List comprehension tiez moze vytvarat generator

```
In [ ]: generator = (i*i for i in range(a, b)) # rozdiel oproti kalsickemu LC je v zatvorkach [] => ()
print(generator)
print(next(generator))
print(list(generator))
```

Explicitny generator ma ale vacsiu vyjadrovaciu silu

Nie je obmedzeny len na formu ktoru pouziva funkcia map:

```
In [ ]: def generator(funkcia, iterator):
        for i in iterator:
            yield funkcia(i)
```

Na co je to cele dobre?

Lenive vyhodnocovanie - Lazy evaluation

Strategie vyhodnocovania

Skratene vyhodnocovanie (Short-circuit)

Netrpezlive vyhodnocovanie (Eager)

Lenive vyhodnocovanie (Lazy)

Vzdialene vyhodnocovanie (Remote)

Ciastocne vyhodnocovanie (Partial)

[https://en.wikipedia.org/wiki/Evaluation_strategy_\(https://en.wikipedia.org/wiki/Evaluation_strategy\)](https://en.wikipedia.org/wiki/Evaluation_strategy_(https://en.wikipedia.org/wiki/Evaluation_strategy))

Skratene vyhodnocovanie

```
In [ ]: def fun1(pole):
        print('prva')
        return False

        def fun2(pole):
            print('druha')
            return True

        if fun1(pole) or fun2(pole):
            pass
```

Lenive vyhodnocovanie

Oddaluje vyhodnocovanie az do doby, ked je to treba

```
In [ ]: pom = (x*x for x in range(5))
        next(pom) #prvok z generatora sa vyberie az ked ho je treba a nie pri vytvoreni generatora
```

Nedockave vyhodnocovanie

Opak leniveho vyhodnotenia. Vyraz sa vyhodnoti hned ako je priradeny do premennej. Toto je typicky sposob vyhodnocovania pri vacsine programovacich jazykoch.

```
In [ ]: pom = [x*x for x in range(5)]
        pom[4] # vyraz sa hned vyhodnocuje cely
```

Vyhody nedockaveho vyhodnocovania

- programator moze kontrolovat poradie vykonavania
- nemusi sledovat a planovat poradie vyhodnocovania

Nevyhody

- neumožňuje vynechať vykonávanie kódu, ktorý vôbec nie je treba (spomente si na príklad so Sparkom)
- neda sa vykonávať kód, ktorý je v danej chvíli dôležitejší
- programator musí organizovať kód tak, aby optimalizoval poradie vykonavania

Moderne kompilatory ale uz niektore veci vedia optimalizovat za programatora

Vzdialene vyhodnocovanie

- Vyhodnocovanie na vzdialenom pocitaci.
- Hociaky vypoctovy model, ktory spusta kod na inom stroji.
- Client/Server, Message passing, MapReduce, Remote procedure call (RCP)

Partial evaluation

- Viacero optimalizacnych strategií na to aby sme vytvorili program, ktory bezi rychlejsie ako povodny program.
 - Napríklad predpocitavanie kodu na zaklade dát, ktoré sú už v čase kompilácie.
 - Memoization (Memoizácia?) - nevykonávanie (čistých) funkcií s rovnakými vstupmi opakované. V podstate ide o časochovanie výstupov volaní funkcií
 - Partial application - fixovanie niektorých parametrov funkcie a vytvorenie novej s menším počtom parametrov.

Lenive vyhodnocovanie moze zrychlit vyhodnocovanie

```
In [ ]: %%time
print(2+2)
```

```
In [ ]: %%time
import time
def slow_square(x):
    time.sleep(0.2)
    return x**2

generator = map(slow_square, range(10))
print(generator)
```

Funkcia slow_square sa zatiaľ nespustila ani raz. Preto je ten čas tak malý

```
In [ ]: # co sa stane ak budeme chciet transformovat generator na zoznam. Teda spustit ru pomalu funkciu na kazdom
        prvku?
%%time
print(list(generator))
```

```
In [ ]: # Aj ked chceme len cast pola, tak musime transformovat vsetky prvky
%%time
generator = map(slow_square, range(10))
pole = list(generator)
print(pole[:5])
```

```
In [ ]: # Mozeme si ale skusit definovat funkciu, ktora nam vyberie len tu cast prvkov, ktore chceme
def head(iterator, n):
    result = []
    for _ in range(n):
        result.append(next(iterator))
    return result
```

```
In [ ]: %%time
print(head(map(slow_square, range(10)), 5))
```

Ta pomala operacia sa vykonala len tolko krat, kolko sme potrebovali a to co sme nepotrebovali sa nemuselo nikdy vykonat.

```
In [ ]: %%time
# tuto funkciu sme si ale nemuseli definovat sami. Nieco take uz existuje

from itertools import islice
generator = map(slow_square, range(10000))
print(list(islice(generator, 5)))
```

Lenive vyhodnocovanie setri pamat

```
In [ ]: from operator import add
        from functools import reduce

        reduce(add, [x*x for x in range(1000000)])
        reduce(add, (x*x for x in range(1000000))) # rozdiel je len v zatvorkach
```

skusim si vyrobiť funkciu, ktorá mi bude priebežne počítat a vypisovať aktuálnu spotrebu pamäti premenných na halde počas toho ako budeme spocítavať čísla

```
In [ ]: from functools import reduce
        import gc
        import os
        import psutil
        process = psutil.Process(os.getpid())

        def print_memory_usage():
            print(process.memory_info().rss)

        counter = [0] # Toto je hnusný hack a sľubujem, že nabuduce si povieme ako to spraviť lepšie. Spytajte sa
        ma na to!
        # Problem je v tom, že potrebujem počítadlo, ktoré bude dostupné vo funkcii ale zároveň ho potrebujem inic
        ializovať mimo tejto funkcie
        # Teraz som zaspínal funkciu použitím mutable datovej štruktúry a globalného priestoru mien. 2xFuj!
        def measure_add(a, result, counter=counter):
            if counter[0] % 2000000 == 0:
                print_memory_usage()
                counter[0] = counter[0] + 1
            return a + result
```

```
In [ ]: gc.collect()
        counter[0] = 0
        print_memory_usage()
        print(reduce(measure_add, [x*x for x in range(1000000)]))
```

```
In [ ]: gc.collect()
        counter[0] = 0
        print_memory_usage()
        print(reduce(measure_add, (x*x for x in range(1000000))))
```

Ani keď sú funkcie povynarované do seba a kolekcia sa predáva ako parameter, nikdy nie je celá v pamäti

map, filter, reduce aj list comprehension vnútorne pracujú s kolekciami ako s iteratormi

```
In [ ]: gc.collect()
        counter[0] = 0
        print_memory_usage()
        print(reduce(measure_add, filter(lambda x: x%2 == 0, map(lambda x: x*x, range(1000000)))))
        # a pokojne by som to mohol vnarať ďalej
```

Keď vieme, že generator sa vyhodnocuje lenivo, tak nám nič nebráni vložiť do neho nekonečný cyklus

```
In [ ]: def fibonacci():
        """Fibonacci numbers generator"""
        a, b = 1, 1
        while True:
            yield a
            a, b = b, a + b

        f = fibonacci()
```

```
In [ ]: print(list(islice(f, 10)))
```

Voilà nekonečná datová štruktúra ktorá nezahŕňa skoro žiadnu pamäť

veľa, nekonečná dátová štruktúra, ktorá nezabera skoro žiadnu pamäť dokedy ju nechcem materializovať celú.

```
In [ ]: list(fibonacci()) # toto netreba pustat
```

Vedeli by ste to použiť na:

- generator prvocísel?
- citanie z veľmi veľkeho suboru, ktorý vám nevojde do pamäti?
- citanie dát z nejakého senzoru, ktorý produkuje kludne nekonečné množstvo dát?

Dalo by sa to použiť napríklad na čakanie na dáta

Predstavte si, že máte subor, do ktorého nejaký proces zapisuje logy po riadkoch a vy ich spracovávate.

Ako by ste spravili iterovanie cez riadky suboru tak, aby ste čakali na ďalšie riadky ak dojdete na koniec suboru?

inspirované - <http://stackoverflow.com/questions/6162002/whats-the-benefit-of-using-generator-in-this-case>
(<http://stackoverflow.com/questions/6162002/whats-the-benefit-of-using-generator-in-this-case>)

```
In [ ]: %%bash
echo -n 'log line' > log.txt
```

```
In [ ]: import time
```

```
In [ ]: # s generatorom napríklad takto
def read(file_name):
    with open(file_name) as f:
        while True:
            line = f.readline()
            if not line:
                time.sleep(0.1)
                continue
            yield line

lines = read("log.txt")
print(next(lines))
```

```
In [ ]: print(next(lines))
```

```
In [ ]: for line in lines:
        print(line)
```

Toto by som vedel spraviť aj bez generátora ale ...

- nemal by som oddelenu logiku čakania a spracovania riadku
- zneuzívam necístu funkciu print
- nevedel by som priamociaro znovupoužívať generátor, vždy by som to musel kódovať odznova
 - jedine, že by som použil funkciu ako parameter
 - stále tam ale zostáva problém ako vrátiť viacero hodnôt z jednej funkcie
- nevedel by som pekne transparentne, lenivo iterovať

```
In [ ]: while True:
        line = logfile.readline()
        if not line:
            time.sleep(0.1)
            continue
        print line
```

Generator môže byť aj trochu zložitejší, napríklad rekurzívny

Predstavte si takúto stromovú štruktúru

```
In [ ]: class Node(object):
```

```

def __init__(self, title, children=None):
    self.title = title
    self.children = children or []

tree = Node(
    'A', [
        Node('B', [
            Node('C', [
                Node('D')
            ]),
            Node('E'),
        ]),
        Node('F'),
        Node('G'),
    ])

```

```

In [ ]: def node_recurse_generator(node):
        yield node
        for n in node.children:
            for rn in node_recurse_generator(n):
                yield rn

[node.title for node in node_recurse_generator(tree)]

```

<http://stackoverflow.com/posts/7634323/edit> (<http://stackoverflow.com/posts/7634323/edit>)

Uloha na volny cas

vedeli by ste vytvorit datovu strukturu `list_r`, ktora by obsahovala prvky zoznamu a jeho zvysock (first, rest)? Vedeli by ste vytvorit rekurzivne funkcie a generatory, ktore by spracovavali zoznam tak ako ste to robili v LISPe?

Ale castokrat sa to da aj bez pouzitia rekurzie

<http://stackoverflow.com/questions/26145678/implementing-a-depth-first-tree-iterator-in-python>
(<http://stackoverflow.com/questions/26145678/implementing-a-depth-first-tree-iterator-in-python>)

```

In [ ]: from collections import deque

def node_stack_generator(node):
    stack = deque([node]) # tu si uchovavam stav prehľadavania kedže nepouzivam call stack v rekurzii
    while stack:
        # Pop out the first element in the stack
        node = stack.popleft()
        yield node
        # push children onto the front of the stack.
        # Note that with a deque.extendleft, the first on in is the last
        # one out, so we need to push them in reverse order.
        stack.extendleft(reversed(node.children))

[node.title for node in node_stack_generator(tree)]

```

Uloha na volny cas

Vedeli by ste tieto dva generatory upravit pre binarny strom?

Rekurzivny generator sa da napríklad použiť na vyrabanie permutácií

```

In [ ]: def permutations(items):
        n = len(items)
        if n==0:
            yield []
        else:

```