Datové typy

IB111 Základy programování
Radek Pelánek

2018

Rozcvička: Co je jiné?

- smrk, lípa, borovice, jedle
- prase, koza, husa, ovce

Odd one out: varianta pro pokročilé

Odd one out: varianta pro začátečníky

prase, pes, prase, prase

Odd one out: varianta pro začátečníky

prase, pes, prase, prase

- vstup: seznam
- výstup: prvek, který je v seznamu osamocen

Odd one out: základní řešení

```
def odd_one_out(alist):
    for x in alist:
        count = 0
        for y in alist:
            if x == y:
                count += 1
        if count == 1:
            return x
    return None
```

Práce s daty

zpracování dotazníku, hledání cesty v bludišti, předpověď počasí, úprava obrázků

- Jaká data budu zpracovávat?
- Jaká data budu potřebovat k řešení problému?
- Jaké operace s daty budu chtít provádět?
- Jak rychle budu chtít, aby operace s daty fungovaly?

Metodika práce s daty

Oddělení dat a funkcionality

Důležitý princip v mnoha oblastech informatiky

Příklad web

- webový portál: oddělení funkcionality, dat a vzhledu
- typická realizace:
  - funkcionalita – program (Python, PHP...)
  - data – databáze (MySQL...)
  - vzhled – grafický styl (CSS)

Ukázka nevhodného kódu

```
...
if currency == 'euro':
    value = amount * 25.72
elif currency == 'dollar':
    value = amount * 21.90
elif currency == 'rupee':
    value = amount * 0.34
...
```

Reálnější příklad

```
def print_stats():
    ...
    if success_rate < 0.5:
        bg_color = "red"
    elif success_rate < 0.85:
        bg_color = "yellow"
    else:
        bg_color = "green"
    ...
```

Revize

```
def print_stats():
    ...
    bg_color = get_color(success_rate,
                         [0.5, 0.85, 1],
                         ["red", "yellow", "green"])
    ...
```

Další úpravy:

- parametry jako globální konstanty „vytknuté“ na začátek kódu
- použití nějaké standardní „colormap“ (tip: viridis)

Abstraktní datové typy

Datový typ

- rozsah hodnot, které patří do daného typu
- operace, které je možno s těmito hodnotami provádět

Abstraktní datový typ (ADT)

- rozhraní
- popis operací, které chceme provádět (případně i složitost)

Konkrétní datová struktura

- implementace
- přesný popis uložení dat v paměti
- definice funkcí pro práci s těmito daty

Poznámky: hranice není vždy úplně ostrá, rozdíl mezi „formálním“ a „praktickým“ pojetím ADT; nejednotná terminologie „datový typ“, „datová struktura“

Dva pohledy na data

- abstraktní, „uživatelský“
  - operace, která s daty budu provádět
  - co musí operace splňovat, efektivita...
  - *množina: ulož, najdi, vymaž*
  - tento předmět
- konkrétní, implementační
  - jak jsou data reprezentována v paměti
  - jak jsou operace implementovány
  - *hašovací tabulka, binární vyhledávací strom*
  - IB002

Abstraktní pohled na data

Výhody:

- snadný vývoj
- jednodušší přemýšlení o problémech

Riziko:

- svádí k ignorování efektivity

Abstraktní datové typy

Nejpoužívanější ADT:

- seznam
- zásobník
- fronta, prioritní fronta
- množina
- slovník (asociativní pole)

Datový typ seznam: různé varianty

- obsahuje posloupnost prvků
  - stejného typu
  - různého typu
- přidání prvku
  - na začátek
  - na konec
  - na určené místo
- odebrání prvku
  - ze začátku
  - z konce
  - konkrétní prvek
- test prázdnosti, délky
- případně další operace, např. přístup pomocí indexu

Seznamy v Pythonu

opakování

- seznamy v Pythonu velmi obecné
- prvky mohou být různých typů
- přístup skrze indexy
- indexování od konce pomocí záporných čísel
- seznamy lze modifikovat na libovolné pozici

```
a = ['bacon', 'eggs', 'spam', 42]
print(a[1:3])          # ['eggs', 'spam']
print(a[-2:-4:-1])     # ['spam', 'eggs']
a[-1] = 17
print(a)               # ['bacon', 'eggs', 'spam', 17]
print(len(a))          # 4
```

Seznamy v Pythonu – operace

```
s = [4, 1, 3]  # seznam
s.append(x)    # přidá prvek x na konec
s.extend(t)    # přidá všechny prvky t na konec
s.insert(i, x) # přidá prvek x před prvek na pozici i
s.remove(x)    # odstraní první prvek rovný x
s.pop(i)       # odstraní (a vrátí) prvek na pozici i
s.pop()        # odstraní (a vrátí) poslední prvek
s.index(x)     # vrátí index prvního prvku rovného x
s.count(x)     # vrátí počet výskytů prvků rovných x
s.sort()       # seřadí seznam
s.reverse()    # obrátí seznam
x in s         # test, zda seznam obsahuje x
               # (lineární průchod seznamem!)
```

Odd one out: řešení pomocí count

```
def odd_one_out(alist):
    for x in alist:
        if alist.count(x) == 1:
            return x
    return None
```

Generátorová notace pro seznamy

list comprehension
specialita Pythonu

```
s = [x for x in range(1, 7)]
print(s)      # [1, 2, 3, 4, 5, 6]

s = [2 * x for x in range(1, 7)]
print(s)      # [2, 4, 6, 8, 10, 12]

s = [(a, b) for a in range(1, 5)
            for b in ["A", "B"]]
print(s)      # [(1, 'A'), (1, 'B'), (2, 'A'),
              #  (2, 'B'), ...
```

Odd one out: generátorová notace

```
def odd_one_out(alist):
    return [x for x in alist
            if alist.count(x) == 1]
```

Pozn. Mírně odlišné chování od předchozích ukázek – vrací seznam všech osamocených.

Vnořené seznamy

- prvky seznamů mohou být opět seznamy
- použití: vícerozměrná data (např. matice)

```
mat = [[1, 2, 3],
       [4, 5, 6],
       [7, 8, 9]]
print(mat[1][2])      # 6

def null_matrix(m, n):
    return [[0 for col in range(n)]
            for row in range(m)]
```

Pozn. efektivnější způsob práce s maticemi: knihovna `numpy`

Násobení matic

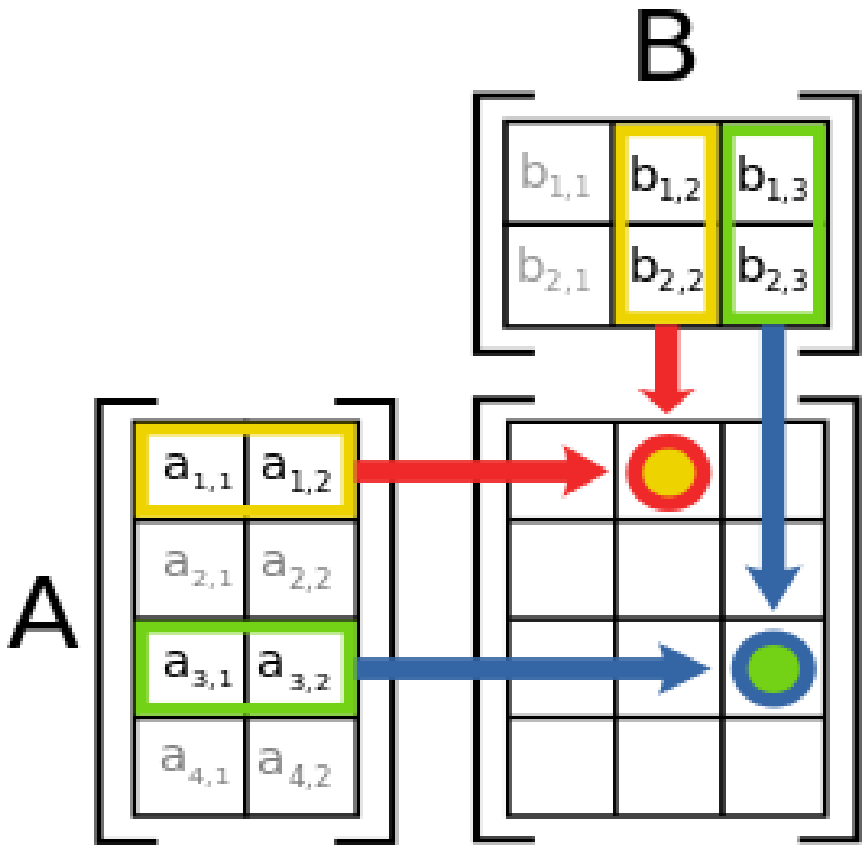

Wikipedia

Vnořené seznamy: Násobení matic

```
def matrix_mult(matL, matR):
  rows = len(matL)
  cols = len(matR[0])
  common = len(matR)
  result = null_matrix(rows, cols)
  for i in range(rows):
    for j in range(cols):
      for k in range(common):
        result[i][j] += matL[i][k] * matR[k][j]
  return result
```

Interpretace dvojitého indexování

- „`data [i][j]`“
  - data indexuji „dvojicí čísel“
  - intuitivní
  - neodpovídá implementaci v Pythonu
- „`data[i] [j]`“
  - indexuji prvním číslem, dostanu seznam
  - tento seznam indexuji druhým číslem
  - speciální případ obecného postupu

Pozn. V Pythonu můžeme mít i `data[i,j]` – to však není seznam, ale slovník indexovaný dvojicí. Více později.

Interpretace složitějšího indexování

čteme „zleva“, resp. „z vnitřku“:

- `mat[2][::-1][0]`
- `sorted(mat[1])[2]`
- `(mat[0]*5)[7]`

Čistě ilustrativní příklady, rozhodně ne ukázky pěkného kódu.

Fronta a zásobník

fronta a zásobník – „seznamy s omezenými možnostmi“

Proč používat něco omezeného?

Fronta a zásobník

fronta a zásobník – „seznamy s omezenými možnostmi“

Proč používat něco omezeného?

- vyšší efektivita implementace
- čitelnější a čistější kód
- „sebe-kontrola“

Sebe-kontrola, historická poznámka: GOTO; xkcd.com/292/

Zásobník

- LIFO = *Last In First Out*
- operace
  - push (vložení)
  - pop (odstranění)
  - top (náhled na horní prvek)
  - empty (test prázdnosti)
- mnohá použití
  - procházení grafů
  - analýza syntaxe
  - vyhodnocování výrazů
  - rekurze

Zásobník v Pythonu

implementace pomocí seznamu

- místo push máme append
- místo top máme [-1]

```
def push(stack, element):
    stack.append(element)

def pop(stack):
    return stack.pop()

def top(stack):
    return stack[-1]

def empty(stack):
    return stack.empty()
```

Příklad aplikace: postfixová notace

- infixová notace
  - operátory mezi operandy
  - `(3 + 7) * 9`
  - je třeba používat závorky
- prefixová notace (polská notace)
  - operátory před operandy
  - `* + 3 7 9`
  - nepotřebujeme závorky
- postfixová notace (reverzní polská notace, RPN)
  - operátory za operandy
  - `3 7 + 9 *`
  - nepotřebujeme závorky

využití zásobníku: převod mezi notacemi, vyhodnocení postfixové notace

Vyhodnocení postfixové notace

```
def eval_postfix(line):
    stack = []
    for token in line.split():
        if token == '*':
            b = pop(stack)
            a = pop(stack)
            push(stack, a * b)
        elif token == '+':
            b = pop(stack)
            a = pop(stack)
            push(stack, a + b)
        else:
            push(stack, int(token))
    return top(stack)
```

Vyhodnocení postfixové notace

vstup	akce	zásobník
7 4 7 + * 8 +	push	
4 7 + * 8 +	push	7
7 + * 8 +	push	7 4
+ * 8 +	+	7 4 7
* 8 +	*	7 11
8 +	push	77
+	+	77 8
		85

Fronta

- FIFO = *First In First Out*
- operace
  - enqueue (vložení)
  - dequeue (odstranění)
  - front (náhled na přední prvek)
  - empty (test prázdnosti)
- použití
  - zpracovávání příchozích požadavků
  - procházení grafu do šířky
- pokročilejší varianta: prioritní fronta

Fronta v Pythonu

- implementace pomocí seznamů snadná, ale neefektivní
  - přidávání a odebírání na začátku seznamu vyžaduje přesun
  - pomalé pro dlouhé fronty
- použití knihovny `collections`
  - datový typ `deque` (oboustranná fronta)
  - vložení do fronty pomocí `append`
  - odebrání z fronty pomocí `popleft`
  - přední prvek fronty je `[0]`

Fronta: ukázka deque

```
from collections import deque
q = deque(["Eric", "John", "Michael"])
q.append("Terry")    # Terry arrives
q.append("Graham")   # Graham arrives
q.popleft()      # Eric leaves
q.popleft()      # John leaves
print(q)         # deque(['Michael', 'Terry', 'Graham']
```

Příklad aplikace: bludiště

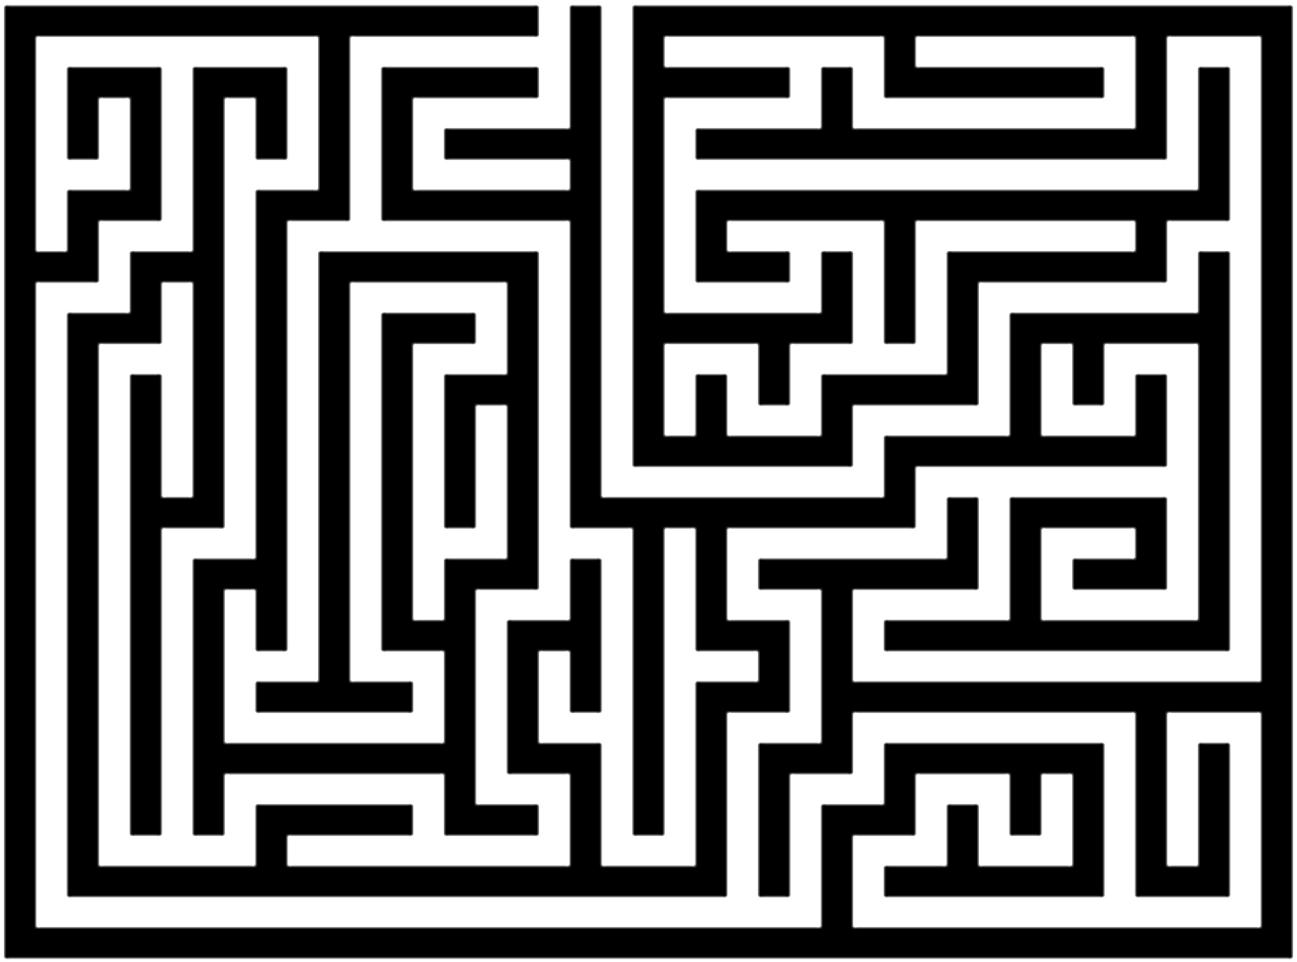

Datový typ množina

- neuspořádaná kolekce dat bez vícenásobných prvků
- operace
  - insert (vložení)
  - find (vyhledání prvku, test přítomnosti)
  - remove (odstranění)
- použití
  - grafové algoritmy (označení navštívených vrcholů)
  - rychlé vyhledávání
  - výpis unikátních slov

Motivace pro množinu

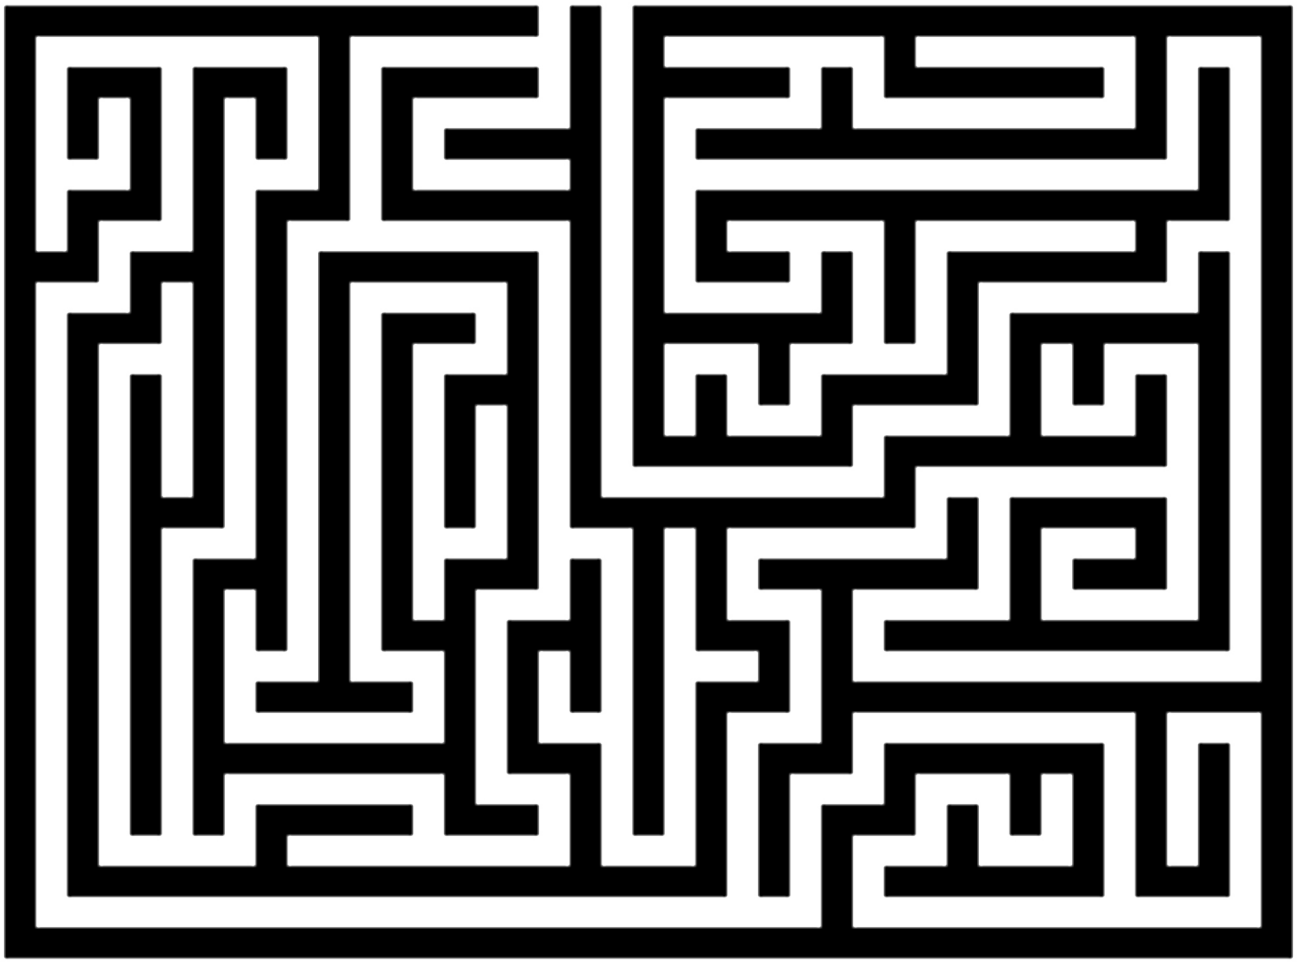

Množina v Pythonu

```
set(alist)                  # vytvoří množinu ze seznamu
len(s)                      # počet prvků množiny s
s.add(x)                    # přidání prvku do množiny
s.remove(x)                 # odebrání prvku z množiny
x in s                      # test, zda množina obsahuje x
s1 <= s2                    # test, zda je s1 podmnožinou s2
s1.union(s2)                # sjednocení množin s1 a s2
s1 | s2                     # -- totéž --
s1.intersection(s2)         # průnik množin s1 a s2
s1 & s2                     # -- totéž --
s1.difference(s2)           # rozdíl množin s1 a s1
s1 - s2                     # -- totéž --
s1.symmetric_diference(s2) # symetrický rozdíl množin
s1 ^ s2                         # -- totéž --
```

Množina v Pythonu

```
basket = ['apple', 'orange', 'apple', 'orange', 'banana
fruit = set(basket)
print(fruit)          # {'orange', 'apple', 'banana'}
print('orange' in fruit)  # True
print('tomato' in fruit)  # False

a = set("abracadabra")
b = set("engineering")
print(a)       # {'a', 'r', 'b', 'c', 'd'}
print(b)       # {'i', 'r', 'e', 'g', 'n'}
print(a | b)   # {'a', 'c', 'b', 'e', 'd', 'g', 'i', 'r
print(a & b)   # {'r'}
print(a - b)   # {'a', 'c', 'b', 'd'}
print(a ^ b)   # {'a', 'c', 'b', 'e', 'd', 'g', 'i', 'r
```

Aplikace množiny

```
def unique(alist):
    return list(set(alist))


def odd_one_out(alist):
    return set(alist)-set([x for x in alist
                           if alist.count(x) > 1])
```

Datový typ slovník

dictionary, map, asociativní pole

- neuspořádaná množina dvojic (klíč, hodnota)
- klíče jsou unikátní
- operace jako u množiny (insert, find, delete)
- přístup k hodnotě pomocí klíče (indexování pomocí `[]`)
- klíče jsou neměnné, ale hodnoty se smí měnit
- příklady použití
  - překlad UČO na jméno, jméno na tel. číslo
  - počet výskytů slov v textu
  - „cache“ výsledků náročných výpočtů

Slovník vs. seznam

zjednodušené srovnání:

- indexování (klíče):
  - seznam: čísla
  - slovník: cokoliv (neměnitelného)
- pořadí klíčů:
  - seznam: fixně dáno
  - slovník: neřazeno

Slovník v Pythonu

```
phone = {"Buffy": 5550101, "Xander": 5550168}
phone["Dawn"] = 5550193
print(phone)
# {'Xander': 5550168, 'Dawn': 5550193, 'Buffy': 55501
print(phone["Xander"])
# 5550168
del phone["Buffy"]
print(phone)
# {'Xander': 5550168, 'Dawn': 5550193}
print(phone.keys())
# dict_keys(['Xander', 'Dawn'])
print("Dawn" in phone)
# True
```

Slovník v Pythonu

užitečné funkce pro slovníky

```
d.keys()                  # vrátí seznam klíčů
d.values()                # vrátí seznam hodnot
d.items()                 # vrátí seznam záznamů (dvojic)
d.get(key, default)       # pokud existuje klíč key, vrátí
                          # jeho hodnotu, jinak vrátí
                          # hodnotu default
d.get(key)                # jako předtím,
                          # jen default je teď None
```

Slovník v Pythonu

`.items()` – použití např. pro kompletní výpis (nikoliv vyhledávání!)

```
for name, num in phone.items():
    print(name + "'s number is", num)
# Xander's number is 5550168
# Dawn's number is 5550193
```

Odd one out: řešení se slovníkem

```
def odd_one_out(alist):
    count = {}
    for x in alist:
        count[x] = count.get(x, 0) + 1
    for x in count:
        if count[x] == 1:
            return x
    return None
```

Odd one out: řešení se slovníkem II

```
def odd_one_out(alist):
    count = {}
    for x in alist:
        count[x] = count.get(x, 0) + 1
    return min(count.keys(), key=count.get)
```

Pozn. Odlišné chování od ostatních ukázek v případě, kdy není splněn předpoklad unikátního osamoceného prvku.

Převod do morseovky

připomenutí: dřívější řešení přes seznamy

```
morse = [".-", "-...",  "-.-.", "-.."] # etc

def to_morse(text):
    result = ""
    for i in range(len(text)):
        if ord("A") <= ord(text[i]) <= ord("Z"):
            c = ord(text[i]) - ord("A")
            result += morse[c] + "|"
    return result
```

Převod do morseovky

```
morse = {"A": ".-", "B": "-...", "C": "-.-."} # etc.

def to_morse(text):
  result = ""
  for c in text:
    result += morse.get(c, "?") + "|"
  return result


# advanced version
def to_morse(text):
  return("|".join(list(map(lambda x: morse.get(x, "?"),
                           text))))
```

Substituční šifra

```
def encrypt(text, subst):
    result = ""
    for c in text:
        if c in subst:
            result += subst[c]
        else:
            result += c
    return result

my_cipher = {"A": "Q", "B": "W", "C": "E"} # etc.

print(encrypt("BAC", my_cipher))
# WQE
```

Frekvenční analýza slov

```
text = """It is a period of civil war. Rebel
spaceships, striking [...] restore freedom to
the galaxy """

output_word_freq(text)
```

```
the      7
to       4
rebel    2
plans    2
of       2
her      2
...
```

Frekvenční analýza slov

```
def is_word_char(char):
    return char not in '!"#$%&\'()*+,-./:;<=>?@[\\]^_`
```

```
def word_freq(text):
    text = "".join(filter(is_word_char, text))
    text = text.lower()
    word_list = text.split()
    freq = {}
    for word in word_list:
        freq[word] = freq.get(word, 0) + 1
    return freq
```

Výpis

```
def output_word_freq_simple(text):
    freq = word_freq(text)
    for word in freq:
        print(word, "\t", freq[word])
```

Jak udělat výpis seřazený podle četnosti a vypisovat pouze nejčetnější slova?

Řazení výstupu: pomocný seznam dvojic

```
def output_word_freq(text, topN=10):
    freq = word_freq(text)
    tmp = [(freq[word], word) for word in freq]
    tmp.sort(reverse=True)
    for count, word in tmp[:topN]:
        print(word, "\t", count)
```

Řazení výstupu: využití lambda funkce

```
def output_word_freq(text, topN=10):
    freq = word_freq(text)
    words = sorted(freq, key=lambda x: -freq[x])
    for word in words[:topN]:
        print(word, "\t", freq[word])
```

Indexování slovníku

slovník můžeme indexovat „neměnitelnými“ datovými typy

- čísla
- řetězce
- dvojice
- n-tice (neměnná forma seznamu)

Indexování slovníku n-ticí

```
data = {}
data[(1, 5)] = "white king"
data[2, 6] = "black rook"
print(data.keys()) #dict_keys([(1, 5), (2, 6)])
```

Můžeme vynechávat kulaté závorky u n-tice.

Pozor na rozdíl:

- `data[x][y]` – seznam seznamů
- `data[x, y]` – slovník indexovaný dvojicí

Shrnutí

- datové typy: abstraktní vs konkrétní
- seznam, vnořený seznam („vícerozměrné pole“)
- zásobník, fronta
- množina
- slovník