Regulární výrazy, práce s daty

IB113
Radek Pelánek

2022

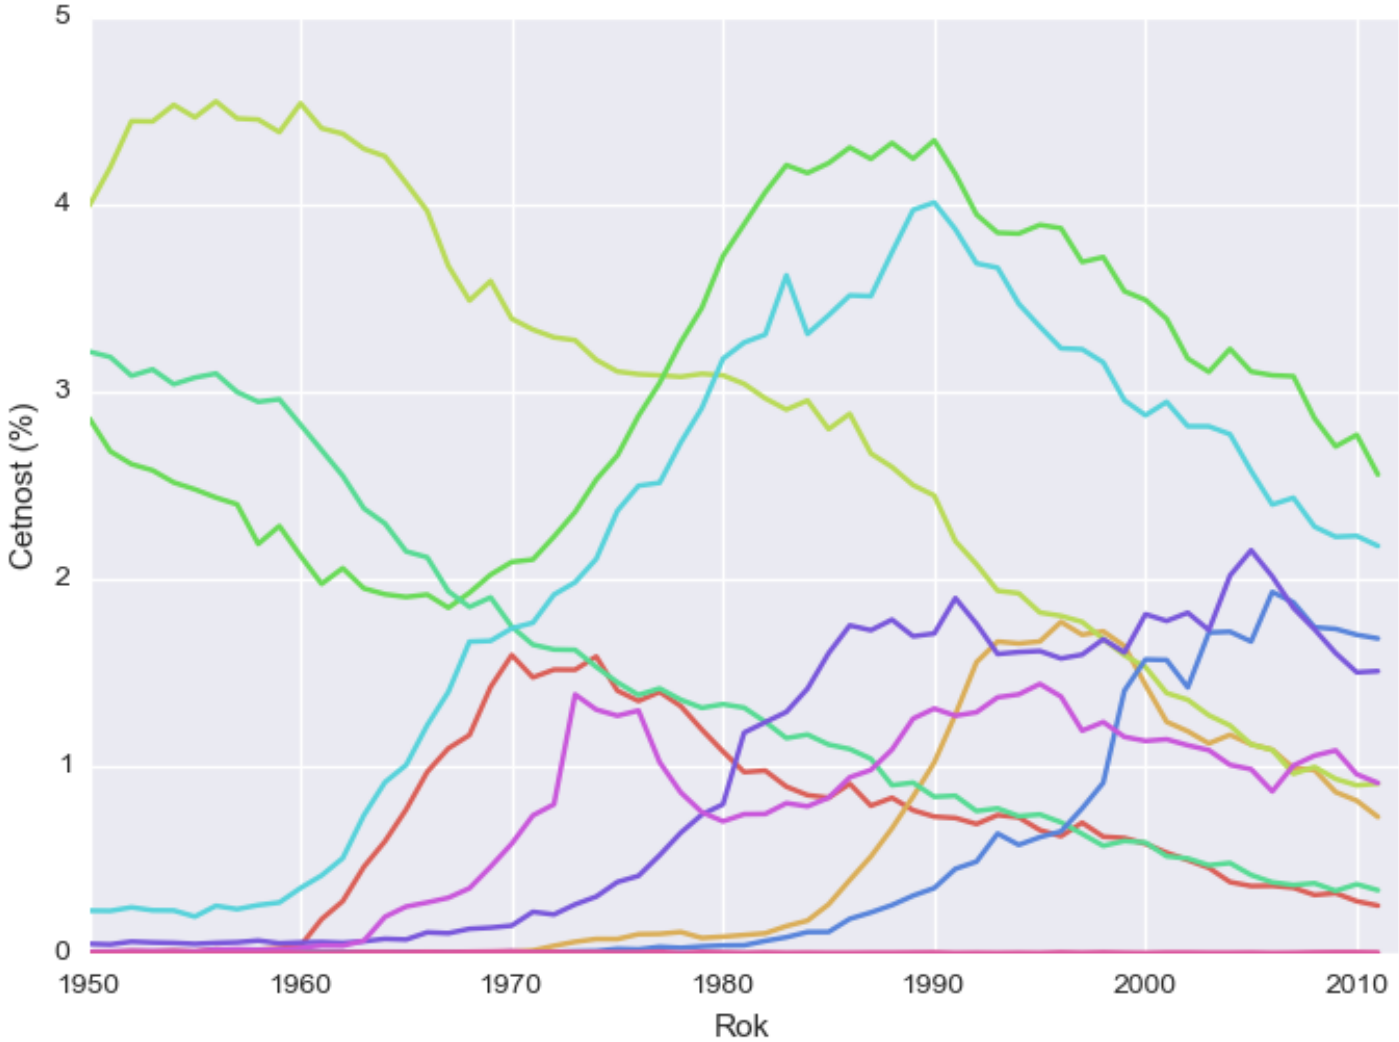

JAN, JAROSLAV, JIŘÍ, MAREK, MATĚJ, NIKOLA, ONDŘEJ, RADEK, TOMÁŠ, VALDEMAR

Šifra

Nechci se tím zabývat donekonečna. Oběhal jsem dvaadvacet ministerstev, schvalovala to i vláda. Požádali jsme o vyjádření rakouskou stranu a podložili návrh lamelami. Nechyběla tomu ostrost, jak potvrdil novinový článek i matematická analýza.

(šifrovací hra Sendvič, 2020)

Dnešní přednáška

Příklady a techniky relevantní k situaci:

- mám data (text, tabulková data)
- chci získat:
  - „vhled“
  - konkrétní informace
  - transformovaná data

Regulární výrazy: motivace

- vyhledání e-mailových adres v textu
- vyhledání odkazů v HTML dokumentu
- náhrada „jméno příjmení“ za „příjmení jméno“
- změna formátu datumů
- odstranění bílých znaků

Regulární výrazy

nástroj pro hledání „vzorů“ v textu

- programování
- textové editory
- příkazová řádka: např. `grep`
- teorie: formální jazyky, konečné automaty

Příklad: `^To:\s*(fi|kit)(-int)?@fi\.muni\.cz`

Regulární výrazy

- obecně používaný nástroj
- syntax velmi podobná ve většině jazyků, prostředí
- bohatá syntax
- následuje „ochutnávka“, ukázky základního využití v Pythonu

http://xkcd.com/208/

Ukázka

Naivní způsob hledání e-mailových adres v textovém souboru:

```
import re
f = open("testovaci-soubor.txt")
for line in f.readlines():
    if re.search(r'[a-z]+@[a-z]+\.cz', line):
        print(line)
f.close()
```

Znaky a speciální znaky

- základní znak „vyhoví“ právě sám sobě
- speciální znaky: `. ^ $ * + ? { } [ ] \ | ( )`
  - umožňují konstrukci složitějších výrazů
  - chceme, aby odpovídaly příslušnému symbolu $\Rightarrow$ prefix \

Skupiny znaků

`[abc]` = jeden ze znaků `a`, `b`, `c`
`[^abc]` = cokoliv jiného než `a`, `b`, `c`

`\d`	Čísla: `[0-9]`
`\D`	Cokoliv kromě čísel: `[^0-9]`
`\s`	Bílé znaky: `[ \t\n\r\f\v]`
`\S`	Cokoliv kromě bílých znaků: `[^ \t\n\r\f\v]`
`\w`	Alfanumerické znaky: `[a-zA-Z0-9_]`
`\W`	Nealfanumerické znaky: `[^a-zA-Z0-9_]`

Speciální symboly

.	libovolný znak
^	začátek řetězce
$	konec řetězce
|	alternativa – výběr jedné ze dvou možností

Příklady

Jaký je význam následujících výrazů?

- `kocka|pes`
- `^[Pp]rase$`
- `\d[A-Z]\d \d\d\d\d`

Opakování

`*`	nula a více opakování
`+`	jedno a více opakování
`?`	nula nebo jeden výskyt
`{m,n}`	m až n opakování

Pozn. `*`, `+` jsou „hladové“, pro co nejmenší počet opakování `*?`, `+?`

Příklady

Jaký je význam následujících výrazů?

- `^\s*Nadpis`
- `^a.+a$`
- `\d{3}\s?\d{3}\s?\d{3}`
- `[a-z]+@[a-z]+\.cz`
- `^To:\s*(fi|kit)(-int)?@fi\.muni\.cz`

Příklady

Která z následujících slov vyhoví jednotlivým výrazům?

	`p[ars]e`	`p[ars]*e`	`p[^ars]e`
`ps`			
`pes`			
`pse`			
`poe`			
`prase`			
`poklice`			

Příklady

Která z následujících slov vyhoví jednotlivým výrazům?

	`p[ars]e`	`p[ars]*e`	`p[^ars]e`
`ps`	×	×	×
`pes`	×	✓	×
`pse`	✓	✓	×
`poe`	×	×	✓
`prase`	×	✓	×
`poklice`	×	×	×

Kontrola tabulky v Pythonu

```
import re
texts = ["ps","pes","pse","poe","prase","poklice"]
regexps = [ r'p[ars]e', r'p[ars]*e', r'p[^ars]e' ]

for text in texts:
    print(text, end=" ")
    for regexp in regexps:
        if re.search(regexp, text):
            print(1, end=" ")
        else:
            print(0, end=" ")
    print()
```

Šifra

Nechci se tím zabývat donekonečna. Oběhal jsem dvaadvacet ministerstev, schvalovala to i vláda. Požádali jsme o vyjádření rakouskou stranu a podložili návrh lamelami. Nechyběla tomu ostrost, jak potvrdil novinový článek i matematická analýza.

(šifrovací hra Sendvič, 2020)

Řešení šifry

Nechci se tím zabývat dONEkONEčna. Oběhal jsem DVAaDVAcet miniSTErSTEv, schVALoVALa to i vláda. Požádali jsme o vyjádření raKOUsKOU stranu a podložili návrh LAMeLAMi. Nechyběla tomu OSTrOST, jak potvrdil NOViNOVý článek i MATeMATická analýza.

Jak hledat vhodná slova při vytváření šifry?

Backreference

- „odkaz“ na předchozí část textu
- pomocí \1, \2, \3, ...
- příklad: slova, která obsahují opakovaně stejnou trojici písmen
  - **sta**ro**sta**
  - p**eri**f**eri**e
- jak zapsat regulární výraz?

Backreference a trojice písmen

- seznam slov, např.

  `https://wiki.korpus.cz/doku.php/seznamy:srovnavaci_seznamy`

- regulární výrazy:
  - `^(...).*\1$`
  - `.(...).*\1.`
  - `(...).\1`
- výstupy např.:
  - **ost**r**ost**
  - **ska**li**ska**
  - b**ram**bo**rami**
  - m**ult**ik**ult**urni

Bez regulárních výrazů

Varianta „uvnitř slova“:

```
def triple_match(word):
    for i in range(1, len(word)-3):
        for j in range(i+1, len(word)-3):
            if word[i:i+3] == word[j:j+3]:
                return True
    return False
```

Je to ekvivalentní?

Detekce opakovaných trojic

- regulární výraz: `.(...).*\1.`
- kontrola podmínky: `word[i:i+3] == word[j:j+3]`
- rozdílné chování: skl**enene**ho, k**ovovo**u, ko**cicic**h

Co je správně?

Regulární výrazy: xkcd

http://xkcd.com/1313/
http://www.explainxkcd.com/wiki/index.php/1313:_Regex_Golf
https://regex.alf.nu/

Regulární výrazy v Pythonu

- knihovna `re` (`import re`)
- `re.match` – hledá shodu na začátku řetězce
- `re.search` – hledá shodu kdekoliv v řetězci
- (`re.compile` – pro větší efektivitu)
- `re.sub` – nahrazení
- „raw string“ – r'vyraz' – nedochází k interpretaci speciálních znaků jako u běžných řetězců v Pythonu

Regulární výrazy v Pythonu: práce s výsledkem

- match/search vrací „MatchObject“ pomocí kterého můžeme s výsledkem pracovat
- pomocí kulatých závorek () označíme, co nás zajímá

Regulární výrazy v Pythonu: práce s výsledkem

```
>>> m = re.match(r'(\w+) (\w+)', \
                 'Isaac Newton, fyzik')
>>> m.group(0)
'Isaac Newton'
>>> m.group(1)
'Isaac'
>>> m.group(2)
'Newton'
```

Regulární výrazy v Pythonu: nahrazení

```
import re

text = 'Petr Novak, 329714, FI B-AP BcAP'
print(re.sub(r'(\w*) (\w*), (\d*)',
             r'\2 \1, UCO=\3',
             text))

# 'Novak Petr, UCO=329714, FI B-AP BcAP'
```

KvIS: Filter list

```
import re

def filter_list(regexp, alist):
    output = []
    for word in alist:
        if re.search(regexp, word):
            output.append(word)
    return output
```

KvIS: program 1

```
import re

def filter_list(regexp, alist):
    output = []
    for word in alist:
        if re.search(regexp, word):
            output.append(word)
    return output

fruits = ['apple', 'banana', 'pear', 'blackberry',
          'fig', 'peach']

print(filter_list(r'a.*e', fruits))
```

KvIS: program 2

```
import re

def filter_list(regexp, alist):
    output = []
    for word in alist:
        if re.search(regexp, word):
            output.append(word)
    return output

nums = ['1.2', '3', '5.832', '428', '1.55']

print(len(filter_list(r'\d.\d', nums)))
```

KvIS: program 3

```
import re

def filter_list(regexp, alist):
    output = []
    for word in alist:
        if re.search(regexp, word):
            output.append(word)
    return output

names = ['Kremilek a Vochomurka', 'Maxipes Fik',
         'Rakosnicek', 'Mala carodejnice',
         'Tom a Jerry']
print(len(filter_list(r'^\w*\s\w*$', names)))
```

KvIS: program 4

```
import re

def decide(regex, string):
    if re.search(regex, string):
        return 'Y'
    return 'N'

for regex in [r'A.I', r'A.*I', r'A.*I$']:
    print(decide(regex, 'PARDUBICE'), end="")
```

KvIS: program 5

```
import re

text = 'FI MU, Botanicka 68a, 602 00 Brno'

m = re.match(r'.*, (\w*).*,[\s\d]*(\w*)$', text)

print(m.group(1)+ ' ' + m.group(2))
```

KvIS: program 6

```
import re

text = 'Petr /vykopal#sloveso/ diru.'

text = re.sub(r'/(.*)#(.*)/',
              r'<span cat="\2">\1</span>',
              text)

print(text)
```

KvIS: program 7

```
text = 'one two  three'

text.split('e')

print(len(text))
```

KvIS: program 8

```
def process(alist):
    output = []
    for x in alist:
        if isinstance(x, str):
            output.append(x)
    return output

alist = [3, '2.4', '1', 8.2, '2']

print("+".join(process(alist)))
```

KvIS: program 9

```
def magic(alist):
    for i in range(len(alist)):
        alist[i] = alist[i].count('a')

fruits = ['apple', 'banana', 'fig']
magic(fruits)
print(fruits)
```

Analýza textu

- vstup: text (v textovém souboru)
- výstup: zajímavé statistiky
  - délka vět, slov
  - nejčastější slova (určité minimální délky)
  - frekvence písmen, digramy, trigramy

$\Rightarrow$ *cvičení*

Analýza textu

statistiky délky slov a vět:

- $\bar{x}$ – průměr
- s – směrodatná odchylka (míra variability)

	slova		**věty**	
	$\bar{x}$	s	$\bar{x}$	s
Starý zákon	4.3	2.3	14.9	7.8
Čapek	4.5	2.5	14.9	13.3
Pelánek	5.9	3.6	13.5	6.9
Wikipedie	5.6	3.0	14.8	8.3

Analýza textu – dekompozice problému

1. text $\rightarrow$ seznam délek slov (vět)
2. seznam délek $\rightarrow$ statistiky
3. statistiky (pro více textů) $\rightarrow$ výpis

Imitace textu

- vstup: rozsáhlý text
- výstup: náhodně generovaný text, který má „podobné charakteristiky“ jako vstupní text
- imitace na úrovni písmen nebo slov

Náhodnostní imitace vstupního textu

I špiské to pole kavodali pamas ne nebo kdy v Dejný Odm sem uvalini se zabijí s Pan stěží ře, a silobe lo v ne řečekovících blova v nadrá těly jakvěmutelaji rohnutkohonebout anej Fravinci V A pěk finé houty. zal Jírakočítencej ské žil, kdDo jak a to Lorskříže si tomůžu schno mí, kto.

Kterak král kočku kupoval V zemi Taškářů panoval král a zapřisáhl se velikou přísahou že bude pochválena První pán si jí ani nevšimnul zato druhý se rychle shýbl a Jůru pohladil Aha řekl sultán a bohatě obdaroval pana Lustiga koupil od něho telegram z Bombaje v Indii není o nic horší člověk nežli někdo z mých hraček Kdepak mávl Vašek rukou

Základní přístup

1. vstupní text $\Rightarrow$ statistiky textu
2. statistiky $\Rightarrow$ generování náhodného textu

Co jsou vhodné statistiky?

Statistiky textu

- základ: frekvence písmen (slov)
- rozšíření: korelace mezi písmeny (slovy)

příklad: pokud poslední písmeno bylo `a`:

- `e` velmi nepravděpodobné (méně než obvykle)
- `l`, `k` hodně pravděpodobná (více než obvykle)

Implementace

- základní frekvenční analýza – datová struktura seznam nebo slovník
  písmeno $\Rightarrow$ frekvence
- rozšířená analýza – seznam seznamů nebo slovník slovníků
  písmeno $\Rightarrow$ { písmeno $\Rightarrow$ frekvence }

generování

- podle aktuálního písmene získám frekvence
- vyberu náhodné písmeno podle těchto frekvencí – „vážená ruleta“

Reprezentace dat

- seznam seznamů – tabulka 26×26, pouze pro malá písmena anglické abecedy
- slovník slovníků – pro libovolné symboly

Korelace písmen: seznamy

```
def letter_ord(char):
    return ord(char) - ord('a')


def letter_correlations(text):
    counts = [[0 for a in range(26)]
              for b in range(26)]
    for i in range(len(text)-1):
        a = letter_ord(text[i])
        b = letter_ord(text[i+1])
        if 0 <= a <= 26 and 0 <= b <= 26:
            counts[a][b] += 1
    return counts
```

Výpis nejčastějších následujících písmen

```
def most_common_after(letter, counts, top_n=5):
    i = letter_ord(letter)
    letter_counts = [(counts[i][j], chr(ord('a')+j))
                     for j in range(26)]
    letter_counts.sort(reverse=True)
    for count, other_letter in letter_counts[:top_n]:
        print(other_letter, count)
```

Korelace písmen: slovníky

```
def symbol_correlation(text):
  counts = {}
  last = " "
  for symbol in text:
    if last not in counts:
      counts[last] = {}
      counts[last][symbol]=counts[last].get(symbol,0)\
                                + 1
    last = symbol
  return counts
```

Tip pro kratší kód: `defaultdict`

Výpis nejčastějších následujících písmen

```
def most_common_after_symbol(symbol, counts, top_n=5):
    print(sorted(counts[symbol].keys(),
                 key=lambda s:
                 -counts[symbol][s])[:top_n])
```

Imitace textu

```
def get_next_letter(current, counts):
    total = sum(counts[current].values())
    r = random.randint(0, total-1)
    for symbol in counts[current].keys():
        r -= counts[current][symbol]
        if r < 0:
            return symbol
    return " "

def imitate(counts, length=100):
    current = " "
    for _ in range(length):
        print(current, end="")
        current = get_next_letter(current, counts)
```

Imitace textu: rozšíření

- nebrat v potaz pouze předcházející písmeno, ale k předcházejících písmen
- *doporučené cvičení*

Imitace sofistikovaněji

- Recurrent Neural Networks – dokáží postihnout i složitější aspekty jazyka
- básně, recepty, Wikipedia články, zdrojové kódy, ...

http://karpathy.github.io/2015/05/21/rnn-effectiveness/

```
PANDARUS:
Alas, I think he shall be come approached and the day
When little srain would be attain'd into being never fed,
And who is but a chain and subjects of his death,
I should not sleep.

Second Senator:
They are away this miseries, produced upon my soul,
Breaking and strongly should be buried, when I perish
The earth and thoughts of many states.

DUKE VINCENTIO:
Well, your wit is in the care of side and that.

Second Lord:
They would be ruled after this chamber, and
my fair nues begun out of the fact, to be conveyed,
Whose noble souls I'll have the heart of the wars.
```

Statistiky jmen

- data: četnosti jmen, příjmení podle roků, krajů, ...
- zdroj: Ministerstvo vnitra ČR

  Akt. stav: „Ministerstvo vnitra není oprávněno ke zveřejňování statistik / přehledů s charakterem statistik.

  Proto bylo zveřejňování těchto přehledů zrušeno.“
- profiltrovaná data (nejčastější jména):

  `docs.google.com/spreadsheets/d/1tbhl-sHEnDOUnbxXOBXf9CaWJb5OtyyOabpOHX6gioc`
- **doporučené cvičení**
  - snadno zpracovatelné
  - zajímavá data
  - cvičení na vymýšlení otázek
- následuje několik ukázek pro inspiraci ...

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	**JMÉNO**	**1950**	**1951**	**1952**	**1953**	**1954**	**1955**	**1956**	**1957**	**1958**	**1959**	**1960**	**1961**	**1962**
2	**ADAM**	15	10	17	17	7	10	9	11	9	11	7	6	10
3	**ADÉLA**	13	16	23	30	19	28	19	22	21	8	12	15	8
4	**ADRIANA**	2	1	3	3	2	3	5	2	7	8	10	6	11
5	**ALENA**	2804	3041	3033	3387	3481	3611	3560	3290	2978	2743	2600	2651	2474
6	**ALEŠ**	100	164	170	222	222	231	255	271	251	280	302	317	397
7	**ALEXANDR**	66	65	72	67	57	70	47	54	62	57	57	90	56
8	**ALEXANDRA**	90	107	78	102	80	87	70	63	58	54	70	60	69
9	**ALICE**	72	78	72	95	91	89	109	88	98	91	103	100	95
10	**ALOIS**	332	312	271	303	282	283	229	215	218	195	148	163	144
11	**ALŽBĚTA**	126	131	112	110	89	83	75	77	78	55	45	43	34
12	**AMÁLIE**	6	4	4	2	0	1	2	1	1	1	1	3	0
13	**ANDREA**	11	7	9	9	12	13	4	14	11	10	25	18	26
14	**ANETA**	0	0	2	1	0	3	0	2	1	2	1	1	1
15	**ANEŽKA**	271	232	220	170	188	157	128	127	106	91	77	52	52
16	**ANNA**	3163	2993	2812	2534	2352	2184	2114	1993	1832	1489	1377	1158	1024
17	**ANTONIE**	131	156	124	127	114	122	106	74	74	63	51	41	32
18	**ANTONÍN**	1355	1308	1254	1163	1114	1054	1068	1010	881	771	748	790	690
19	**BARBORA**	22	31	30	23	31	30	22	25	32	39	35	56	91
20	**BEDŘICH**	157	153	170	146	138	130	144	155	99	108	93	99	88
21	**BLANKA**	592	685	701	704	734	692	718	761	675	575	615	685	674
22	**BLAŽENA**	176	199	172	152	156	124	114	116	112	65	60	65	58
23	**BOHUMIL**	552	576	547	479	487	441	424	449	374	299	327	259	284
24	**BOHUMILA**	262	238	269	265	218	218	190	188	171	159	127	113	93
25	**BOHUSLAV**	415	362	360	357	332	357	318	342	268	245	236	195	177
26	**BOŽENA**	1364	1173	1080	990	946	964	871	758	681	534	492	420	366

Poznámky ke zpracování

- načtení CSV
  - funkce `split` $\rightarrow$ seznam hodnot
  - použití knihovny pro práci s CSV (pro složitější data)
- normalizace (relativní výskyty jmen) – podělit součtem (pro daný rok)
  - různě velké ročníky
  - neúplná data u starých ročníků

Reprezentace dat

slovník mapující jména na seznam počtů výskytů

```
{'Alois': [332, 131, 112], 'Adam': [15, 10, 17]}
print(data[name][year-1950])
```

slovník mapující jména na slovníky mapující roky na počty

```
{'Adam': {1950: 15, 1951: 10},
 'Alois': {1950: 332, 1951: 131}}
print(data[name][year])
```

slovník mapující dvojici jméno+rok na počet výskytů

```
{('Alois', 1951): 131, ('Adam', 1950): 15,
 ('Alois', 1950): 332, ('Adam', 1951): 10}
print(data[name, year])
```

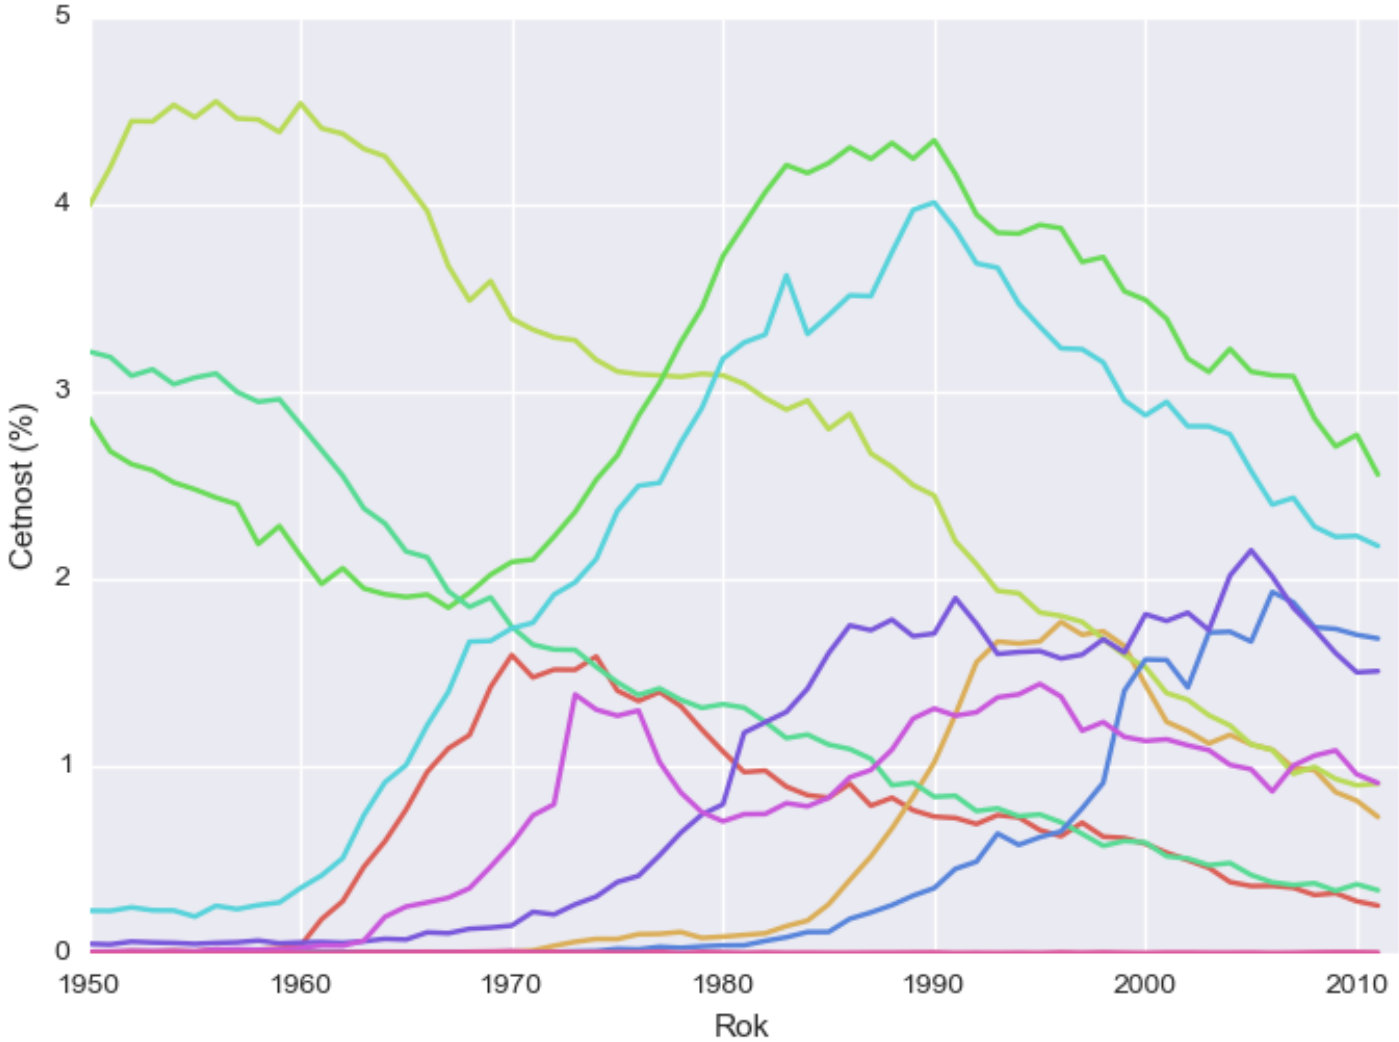

JAN, JAROSLAV, JIŘÍ, MAREK, MATĚJ, NIKOLA, ONDŘEJ, RADEK, TOMÁŠ, VALDEMAR

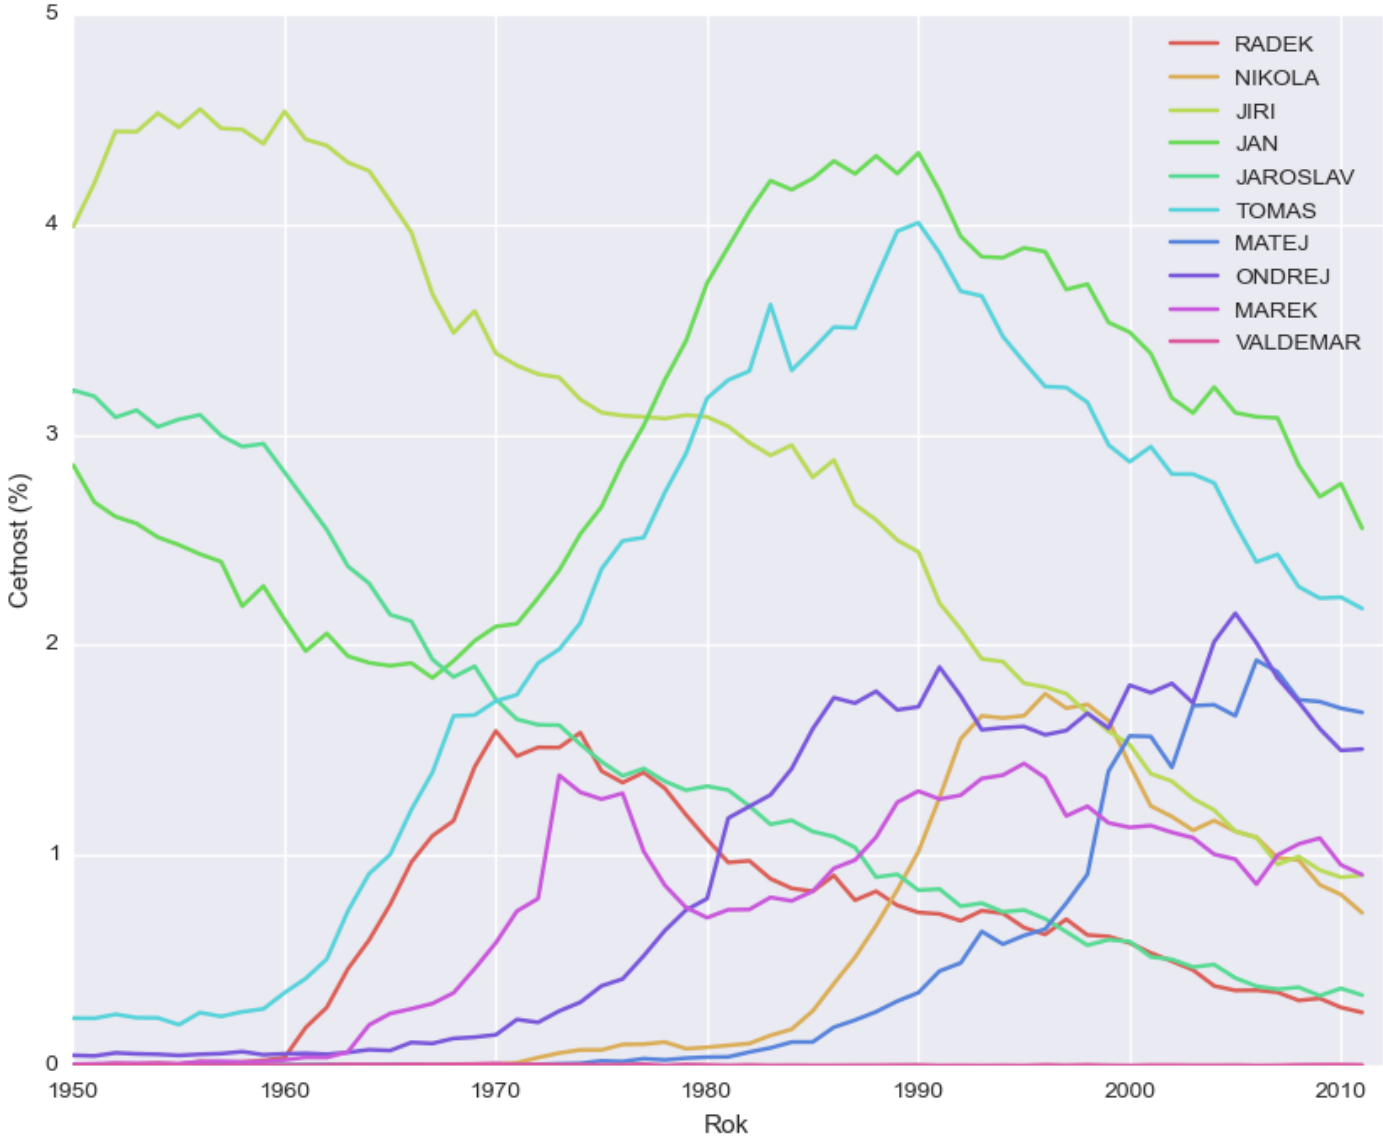
RADEK
NIKOLA
JIRI
JAN
JAROSLAV
TOMAS
MATEJ
ONDREJ
MAREK
VALDEMAR
Cetnost (%)
Rok
0
1
2
3
4
5
1950
1960
1970
1980
1990
2000
2010

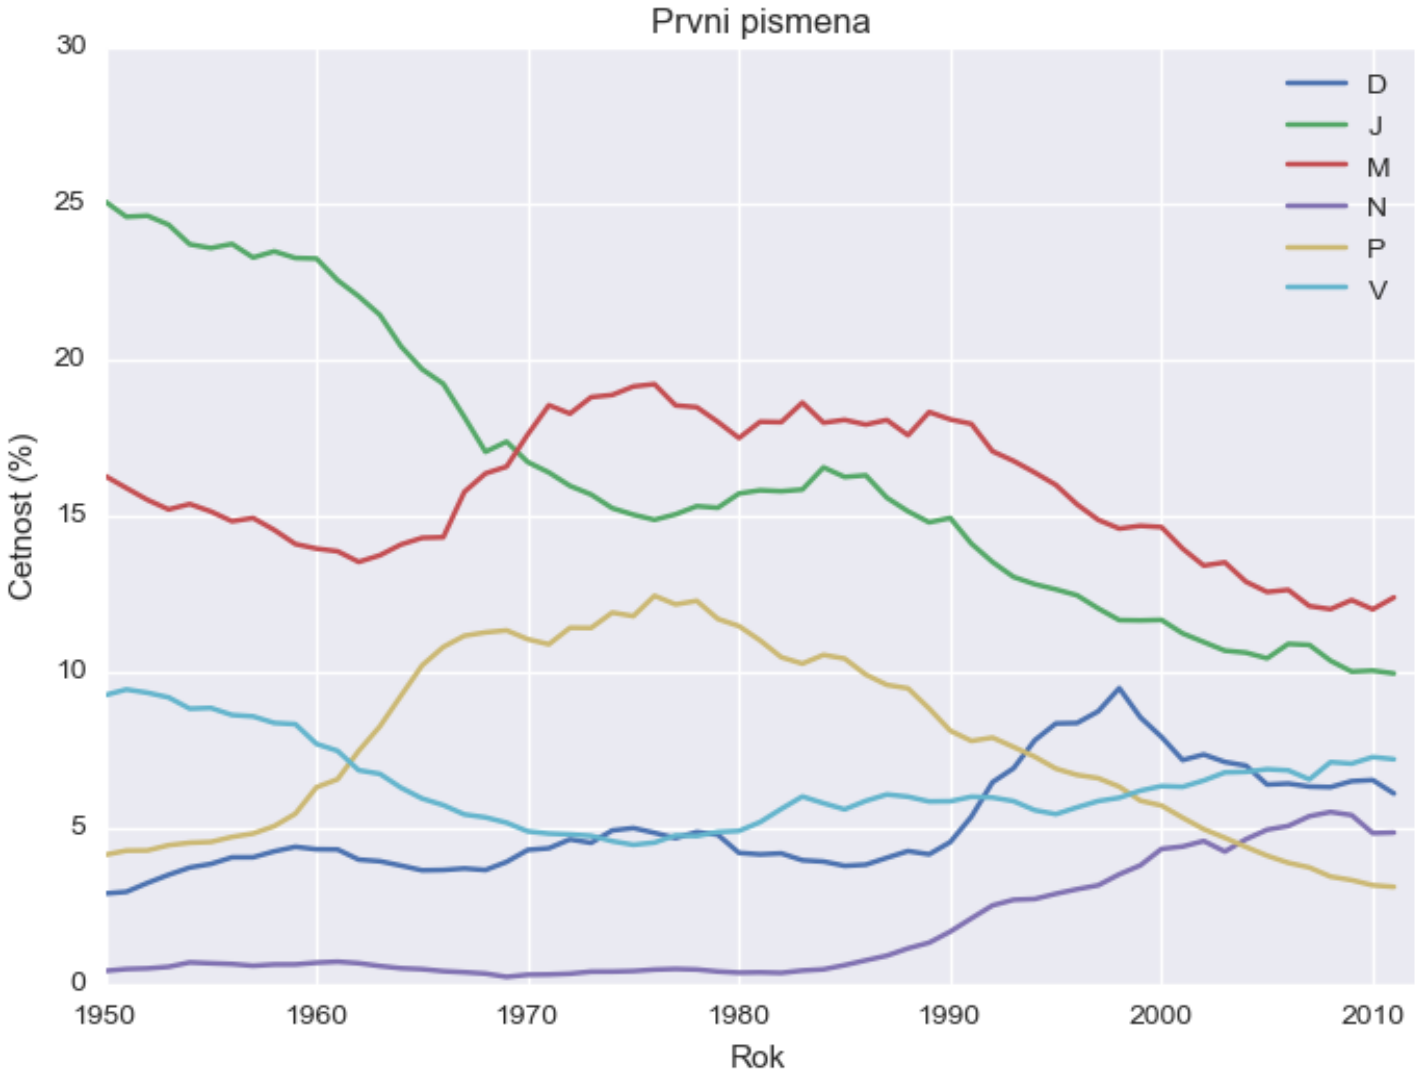
Prvni pismena
Cetnost (%)
Rok
0
5
10
15
20
25
30
1950
1960
1970
1980
1990
2000
2010
D
J
M
N
P
V

Otázky

Co zajímavého můžeme z dat zjistit?

Kladení otázek – důležitá dovednost hodná tréninku.

> Computers are useless. They can only give you answers. (Pablo Picasso)

Identifikace trendů

U kterých jmen nejvíce roste/klesá popularita?

- co to vlastně znamená?
- jak formalizovat?

Nejdelší růst/pokles

Kolik let v řadě roste popularita jména:

- Tobiáš – 14
- Viktorie, Ella, Sofie – 9
- Elen, Tobias – 8

Kolik let v řadě klesá popularita jména:

- Jana – 26
- Martin – 21
- Petra – 11
- Zdeněk – 9

Největší skok v popularitě za 10 let

- alespoň desetinásobný nárůst popularity:
  Sofie, Elen, Amálie, Ella, Nicol, Nella, Tobias
- pokles alespoň o 60 %:
  Petra, Pavlína, Martina

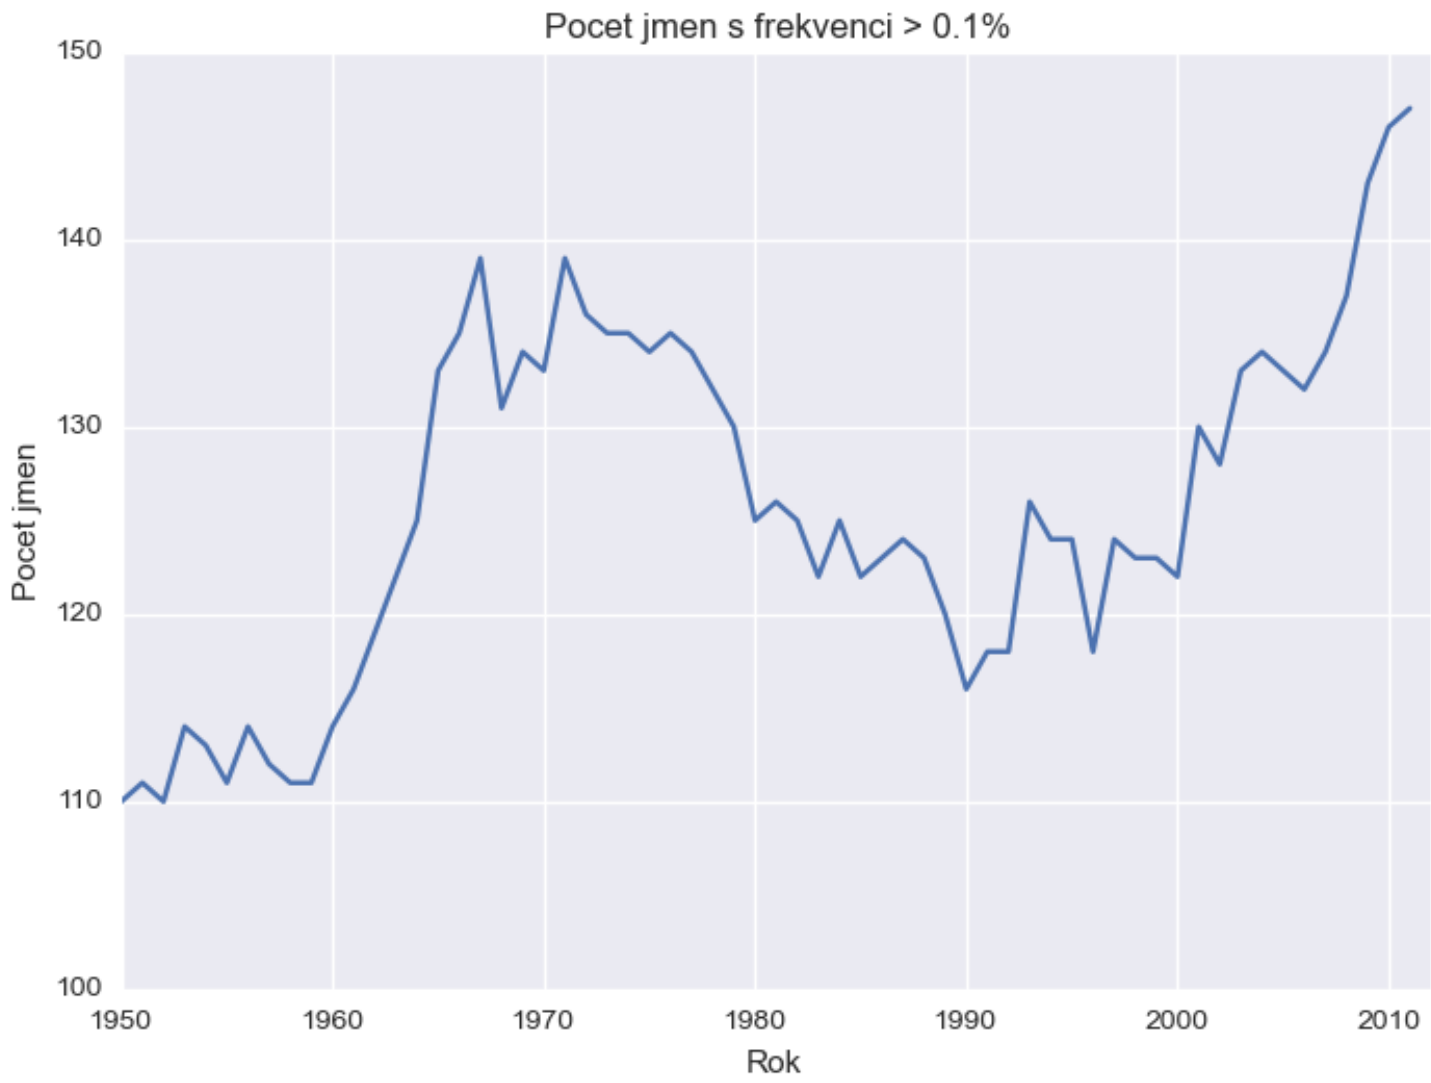
Pocet jmen s frekvenci > 0.1%
150
140
130
120
110
100
Pocet jmen
1950
1960
1970
1980
1990
2000
2010
Rok

Zpracování dat seriózněji

využití existujících knihoven:

- načítání dat ve standardních formátech: HTML, XML, JSON, CSV, ...
- operace s daty: `numpy`, `pandas`
- vizualizace: `matplotlib`
- interaktivní prozkoumávání dat: `ipython`, `jupyter`

Demo ukázka řešení problému

Formát dat pro cvičení z pravopisu:

```
Zb[i/y|01]něk se rád zab[í/ý|01]vá hrou na
b[i/y|10]cí. Tvář mu zdob[í/ý|10] vlasy barvy
ob[i/y|10]lí a vypadá trochu jako hob[i/y|10]t.
Ob[i/y|01]čejně hraje ve svém ob[i/y|01]dlí na
B[i/y|01]stré ulici....
```

Úkol: Převod na čistý výpis (*Zbyněk se rád zabývá hrou na bicí...*).

Doporučené procvičování

https://www.umimeinformatiku.cz/regularni-vyrazy

Kontrolní otázky

- K čemu slouží regulární výrazy?
- Jaký je v regulárních výrazech význam `+`, `*`, `.`, `\s`, `\d`, `\w`, `[ab]`, `$`?
- Jak používáme regulární výrazy v Pythonu?
- Pokud mám tabulku číselných údajů, jak ji mohu načíst, reprezentovat a zpracovat?

Shrnutí

- regulární výrazy
- práce s textem, daty
- využití datových struktur