Algoritmy a programování

Řetězce, práce se soubory

Vojtěch Vonásek

Department of Cybernetics
Faculty of Electrical Engineering
Czech Technical University in Prague

Řetězce (string)

- Složený datový typ
- Lze vytvořit jednoduchými nebo dvojitými uvozovkami

```
1 a = "ahoj"
2 b = 'hello'
```

- Oba způsoby jsou ekvivalentní
- Datový typ string je immutable, tj. nelze měnit jeho vnitřní hodnoty
- Délka řetězce: funkce `len()`
  - `print(len("ahoj"))` → `4`
  - `print(len("0"))` → `1`
  - `print(len(""))` → `0`
- Přístup na jednotlivá písmena — operátor `[]`
  - `a[i]` je i-tý znak v proměnné `a` (číslujeme od 0)
  - `a[0]` je první znak v proměnné `a`
  - `a[len(a)-1]` je poslední znak

Řetězce: vytváření

- Inicializace: operátor =

```
1 emptyString = ""
2 otherString = "some␣text"
```

- Spojování: operátor +

```
1 intro = "Hello"
2 name = "John"
3 text = intro + ",␣" + name
```

- Opakování: operátor *

```
1 fiveSpaces = "␣"*5
```

- Spojení (ne-stringových) proměnných: přetypování funkcí `str()`

```
1 number = 10/2
2 text = "The␣number␣is␣" + str(number)
```

Řetězce: indexování

- Přístup na jednotlivá písmena — operátor `[]`
- Nelze přistupovat na neexistující prvek!

```
1 a = "ahoj"
2 print(a[10])
```

```
    print(a[10])
IndexError: string index out of range
```

Řetězce: použití for+range

- Přístup na jednotlivá písmena — operátor `[]`
- V řídicí proměnné je index

```
1 a = "ahoj"
2 for i in range(len(a)):
3     print(a[i])
```

```
a
h
o
j
```

Řetězce: použití for+in

- For cyklus s operátorem `in` použitý na proměnnou typu string vrací písmena zleva doprava

```
1 a = "ahoj"
2 for letter in a:
3     print(letter)
```

```
a
h
o
j
```

Řetězce: procházení přes for cyklus a []

- Pozor, string je immutable, tj. nelze ho měnit!

```
1 a = "pepa"
2 a[0] = "P"
```

```
    a[0] = "P"
TypeError: 'str' object does not support item
   assignment
```

```
1 a = "ahoj"
2 for i in range(len(a)):
3     a[i] = "*"
```

```
    a[i] = "*"
TypeError: 'str' object does not support item
   assignment
```

Řetězce: použití for+in

- Pozor, string je immutable, tj. nelze ho měnit!

```
1 a = "abc"
2 print(a)
3 for i in a:
4     i = "*"
5     print(i)
6 print(a)
```

```
*
*
abc
```

- Zde měníme hodnotu proměnné `i` (přepíšeme na `'*'`)
- Ale neměníme konkrétní prvek v proměnné `a`

Řetězce: úpravy

- Stringy jsou immutable, nelze je měnit přímo přes opeátor `[]`
- Úpravy (a další operace) s využitím metod třídy String
- Náhrada podřetězce: metoda `replace(oldString, newString)`

```
1 x = "Hahaha!"
2 y = x.replace("a","e")  #x is not changed
3 print(x)
4 print(y)
```

```
Hahaha!
Hehehe!
```

```
1 x = "Python␣is␣cool"
2 y = x.replace("Python","c++")  #x is not changed
3 print(x)
4 print(y)
```

```
Python is cool
c++ is cool
```

Řetězce: úpravy

- Stringy jsou immutable, nelze je měnit přímo přes opeátor `[]`
- Úpravy (a další operace) s využitím metod třídy String
- Náhrada části řetězce: metoda `replace(oldString, newString)`

```
1 x = "text to remove text"
2 y = x.replace("text","")
3 print(x)
4 print(y)
```

```
text to remove text
 to remove
```

Řezy (slices)

- `t[i:j]` vrací řetězec od pozice i do pozice j **(kromě j)**
- `t[i:]` od pozice i do konce
- `t[:j]` od začátku do pozice j **(kromě j)**
- `t[:]` kopie celého řetězce
- Výsledek řezu řetězce je opět řetězec

```
1  t = "abcdefgh"
2  print(t[3:])
3  print(t[:])
4  print(t[:-3])
5  print(t[3:-3])
6  print(t[3:4])
7  print(t[2:5])
8  print(t[1:-1])
9  print(t[4:4])   #!
10 print("*")
```

```
defgh
abcdefgh
abcde
de
d
cde
bcdefg

*
```

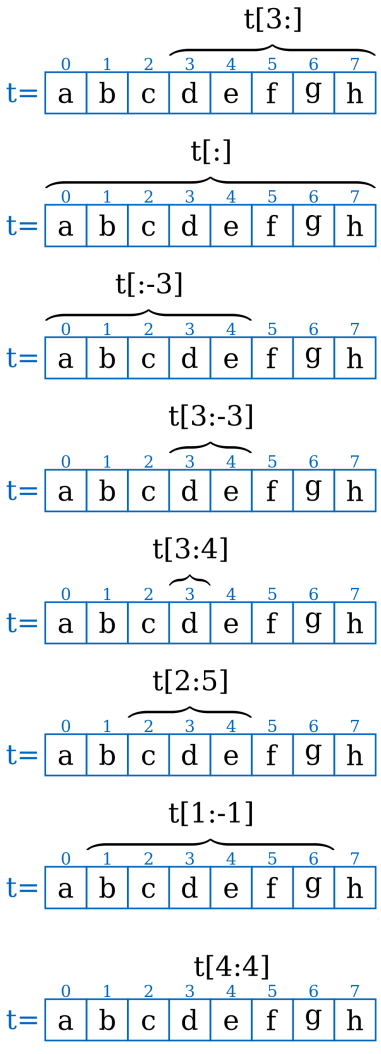

Výpis na obrazovku

`print()`

- Přidává automaticky konec řádku (`\n`)
- Pokud má více argumentů, vkládá mezi ně mezeru

```
1 print("a","b","c")
2 print("*")
```

```
a b c
*
```

- Další argumenty funkce `print()`
  - `sep` — oddělovač, znak mezi argumenty (defaultně mezera)
  - `end` — znak, který se tiskne na konci výpisu (defaultně `\n`)
- `print(a,b,c)` je ekvivaletní `print(a,b,c,sep=" ",end="\n")`

print(): ovlivnění výstupu

- Změnou `sep` nebo `end` můžeme ovlivnit způsob výpisu

```
1 a=1
2 b=2
3 print(a,b, end="|")
4 print("*")
```

```
1 2|*
```

```
1 a = 1
2 b = 2
3 c = 3
4 print(a,b,c, end="\n\n", sep="@")
5 print("*")
```

```
1@2@3


*
```

Zápis řetězců, speciální znaky

- Vytvoření řetězců z písmen abecedy a čísel je triviální
- Jak zapíšeme jiné znaky?

Doplňte program:

```
1 a =
2 print(a)
```

aby vypsal:

```
Peter's son is "Paul"
```

ASCII tabulka

- Datové typy jsou v počítači uloženy v bytech
- V případě řetězců (a txt souborů) se data “zobrazují” ve formě znaků
- Pro správnou interpretaci bytů je třeba znát konverzní tabulku
- ASCII a UTF-8

ASCII

- Definuje význam pro 7bitů (0–127)
- Řídicí znaky (0–31)
  - Ovlivňují výstup
  - Např. nový řádek ($\backslash n$), tabulátor ($\backslash t$)
- Tisknutelné znaky (32–127)
  - Znaky angl. abecedy, čísla, mezera, závorky, znamínka . . .
- Extended ASCII (8 bitů, rozsah 128-255)
  - Znaky národních abeced
  - Pro každý jazyk je jiné rozšíření

ASCII tabulka

ASCII control characters

00	NULL	(Null character)
01	SOH	(Start of Header)
02	STX	(Start of Text)
03	ETX	(End of Text)
04	EOT	(End of Trans.)
05	ENQ	(Enquiry)
06	ACK	(Acknowledgement)
07	BEL	(Bell)
08	BS	(Backspace)
09	HT	(Horizontal Tab)
10	LF	(Line feed)
11	VT	(Vertical Tab)
12	FF	(Form feed)
13	CR	(Carriage return)
14	SO	(Shift Out)
15	SI	(Shift In)
16	DLE	(Data link escape)
17	DC1	(Device control 1)
18	DC2	(Device control 2)
19	DC3	(Device control 3)
20	DC4	(Device control 4)
21	NAK	(Negative acknowl.)
22	SYN	(Synchronous idle)
23	ETB	(End of trans. block)
24	CAN	(Cancel)
25	EM	(End of medium)
26	SUB	(Substitute)
27	ESC	(Escape)
28	FS	(File separator)
29	GS	(Group separator)
30	RS	(Record separator)
31	US	(Unit separator)
127	DEL	(Delete)

ASCII printable characters

32	space	64	@	96	`
33	!	65	A	97	a
34	"	66	B	98	b
35	#	67	C	99	c
36	$	68	D	100	d
37	%	69	E	101	e
38	&	70	F	102	f
39	'	71	G	103	g
40	(	72	H	104	h
41	)	73	I	105	i
42	*	74	J	106	j
43	+	75	K	107	k
44	,	76	L	108	l
45	-	77	M	109	m
46	.	78	N	110	n
47	/	79	O	111	o
48	0	80	P	112	p
49	1	81	Q	113	q
50	2	82	R	114	r
51	3	83	S	115	s
52	4	84	T	116	t
53	5	85	U	117	u
54	6	86	V	118	v
55	7	87	W	119	w
56	8	88	X	120	x
57	9	89	Y	121	y
58	:	90	Z	122	z
59	;	91	[	123	{
60	<	92	\	124	|
61	=	93	]	125	}
62	>	94	^	126	~
63	?	95	_		

Extended ASCII characters

128	Ç	160	á	192	└	224	Ó
129	ü	161	í	193	┴	225	ß
130	é	162	ó	194	┬	226	Ô
131	â	163	ú	195	├	227	Ò
132	ä	164	ñ	196	─	228	õ
133	à	165	Ñ	197	┼	229	Õ
134	å	166	ª	198	ã	230	µ
135	ç	167	º	199	Ã	231	þ
136	ê	168	¿	200	╚	232	Þ
137	ë	169	®	201	╔	233	Ú
138	è	170	¬	202	╩	234	Û
139	ï	171	½	203	╦	235	Ù
140	î	172	¼	204	╠	236	ý
141	ì	173	¡	205	═	237	Ý
142	Ä	174	«	206	╬	238	¯
143	Å	175	»	207	¤	239	´
144	É	176	░	208	ð	240	≡
145	æ	177	▒	209	Ð	241	±
146	Æ	178	▓	210	Ê	242	‗
147	ô	179	│	211	Ë	243	¾
148	ö	180	┤	212	È	244	¶
149	ò	181	Á	213	ı	245	§
150	û	182	Â	214	Í	246	÷
151	ù	183	À	215	Î	247	¸
152	ÿ	184	©	216	Ï	248	°
153	Ö	185	╣	217	┘	249	¨
154	Ü	186	║	218	┌	250	·
155	ø	187	╗	219	█	251	¹
156	£	188	╝	220	▄	252	³
157	Ø	189	¢	221	¦	253	²
158	×	190	¥	222	Ì	254	■
159	ƒ	191	┐	223	▀	255	nbsp

ASCII tabulka

- `ord(letter)`: vrátí číslo znaku v ASCII tabulce
- `chr(number)`: vrátí znak dle ASCII

```
1 text = "ahoj"
2 for letter in text:
3     print("Letter",letter,",␣ord:", ord(letter))
4
5 compose = chr(65) + chr(32) + chr(64)
6 print(compose)
```

```
Letter a , ord: 97
Letter h , ord: 104
Letter o , ord: 111
Letter j , ord: 106
A @
```

UTF-8

- Kódování s proměnlivou délkou (znak je kódován 1 až 4 byty)
- Lze reprezentovat až 1,112,064 znaků (včetně znaků národních abeced)
- Význam prvních 7 bitů (0–127) je shodný s ASCII
- Python nativně podporuje UTF-8
- Python předpokládá, že zdrojový program je vytvořený v UTF-8

Escape sekvence

- Escape sekvence: zápis vybraných řídicích znaků

\’	apostrof
\”	uvozovky
\\	zpětné lomítko
\n	nový řádek (new line)
\r	nový řádek (carriage return)
\t	tabulátor
\b	backspace

```
1 a = "first␣line\nsecond␣line\nthird␣line\n"
2 print(a, end="|")
3 print("normal␣print")
4 b = "\t\tindented␣text\n";
5 print(b,end="|")
```

```
first line
second line
third line
|normal print
                    indented text
|
```

Reprezentace řetězce

- Znaky jsou v počítači uložené v bytech
- Řetězec je sekvence znaků, každý znak je 8-mi bitové číslo (byte)
- Zobrazení řetězců (a txt souborů) přes konverzní tabulku (typicky ASCII, UTF-8)

```
1 a = "ab\nCD\n01\n";
2 print(a)
3 for letter in a:
4     print(ord(letter), end="␣")
```

```
ab
CD
01

97 98 10 67 68 10 48 49 10
```

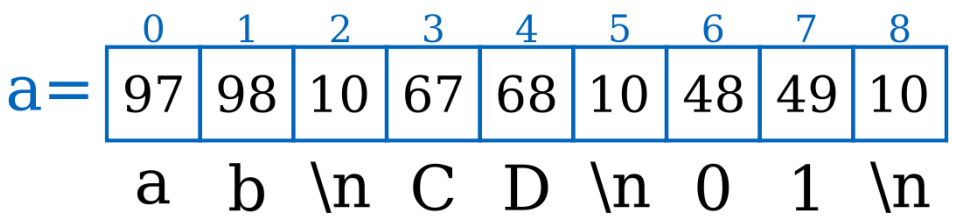

- Znalost použitého kódování je důležitá pro správnou interpretaci (editorem, titulky, browser . . .)
- Ale i pro správnou interpretaci Pythonem
- Python předpokládá, že vstup (program + vstupní soubory) je UTF-8
- Pokud ne, dojde k nesprávné interpretaci znaků
- To může vést na chybu programu, nekonečný cyklus . . .

```
Mě to běží správně, ale Brute mi nepřidělil body!
MÄ~[ to bÄ~[ĹžĂ  sprĂĄvnÄ~[, ale Brute mi nepĹ~YidÄ~[lil body!
MΔ~[ to bΔ~[ĹŸΓ  sprΓ‘vnΔ~[, ale Brute mi nepE~YidΔ~[lil body!
```

- Znalost použitého kódování je důležitá pro správnou interpretaci (editorem/Pythonem)
- Python předpokládá, že vstup je UTF-8
- Pokud ne, dojde k nesprávnému pochopení znaků (chyba programu, nekonečný cyklus apod)
- UTF-8

```
2 číslo = 1
3 dalšíČíslo = číslo + 2
4 print(číslo, dalšíČíslo)
```

```
1 3
```

- Jiné kódování (8859-2)

```
2 èíslo = 1
3 dal¹íÈíslo = èíslo + 2
4 print(èíslo, dal¹íÈíslo)
```

```
File "program8859-2.py", line 1
SyntaxError: Non-UTF-8 code starting with '\xe8' in file program8859-2.py
 on line 1, but no encoding declared; see http://python.org/dev/peps/pep-
0263/ for details
```

Doporučení

- V programech nepoužíváme české (a jiné národní) znaky
- Ani v komentářích

```
2 èíslo = 1
3 dal¹íÈíslo = èíslo + 2
4 print(èíslo, dal¹íÈíslo)
```

```
File "program8859-2.py", line 1
SyntaxError: Non-UTF-8 code starting with '\xe8' in file program8859-2.py
 on line 1, but no encoding declared; see http://python.org/dev/peps/pep-
0263/ for details
```

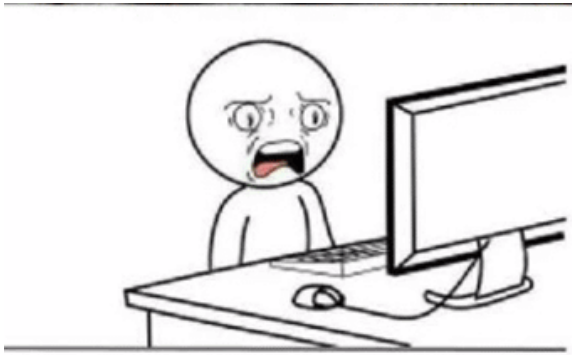

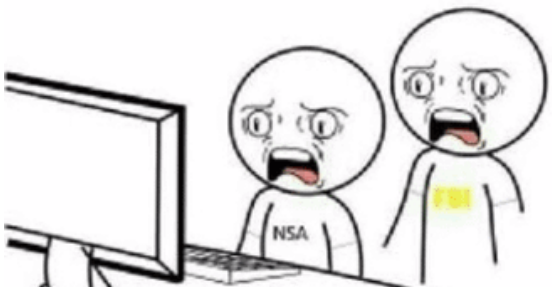


```
namespace 🔵 = std;
using 🔢 = int;
using 💀 = void;
using 🕐 = time_t;
using 👌 = bool;
#define 👂 auto
#define 👀 enum
#define 👎 false
#define 👍 true
#define 😈 "evil"
#define 💪 🔵::make_shared
#define 🍸 virtual
#define 🖥️ 🔵::cout
#define 🚽 🔵::endl
template<class 🔮>
using 📚 = 🔵::vector<🔮>;
template<class 🔮>
using 👇 = 🔵::shared_ptr<🔮>;

👀 🙈 { 🐶, 🙈, 🙉, 🙊 };
🔢 🎲() { return 🔵::rand(); }
👌 😎() { return 👎; }

struct 🍴 { 🍸 💀 👀() = 0; };
struct 🍎 : 🍴 { 🍸 💀 👀() { 🖥️ << "🍎" << 🚽; }; };
struct 🍉 : 🍴 { 🍸 💀 👀() { 🖥️ << "🍉" << 🚽; }; };
struct 🍒 : 🍴 { 🍸 💀 👀() { 🖥️ << "🍉" << 🚽; }; };
struct 🍓 : 🍴 { 🍸 💀 👀() { 🖥️ << "🍓" << 🚽; }; };
struct 🍐 : 🍴 { 🍸 💀 👀() { 🖥️ << "🍐" << 🚽; }; };
struct 🍎 : 🍴 { 🍸 💀 👀() { 🖥️ << "🍎" << 🚽; }; };

🔢 main()
{
    if (😎() == 👎)
        🖥️ << "💩" << 🚽;

    📚<👇<🍴>> 🍽️ = { 💪<🍎>(), 💪<🍉>(), 💪<🍒>(), 💪<🍐>(), 💪<🍎>() };

    for (👂 🍏 : 🍽️)
        🍏->👀();

    return 🎲();
}
```

Soubory: reprezentace

- Soubor je posloupnost bytů

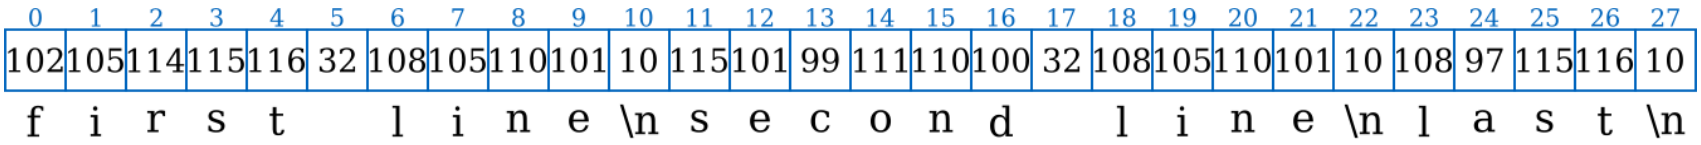

- Pokud je soubor považován za textový, jsou jednotlivé byty (nebo jejich skupiny) interpretovány jako znaky (dle konverzní tabulky)
- Často používané tabulky: ASCII, UTF-8
- Zobrazení souboru bude následující

```
first line
second line
last
```

Soubory: čtení

- Otevření pro čtení: `f = open(jmeno_souboru, "rt")`
- ”rt”— ”read text”: soubor je otevřen **pro čtení** (textového souboru)
- Po otevření ukazuje `f` (“handle”) na začátek souboru
- `readline()`: string znaků od aktuální pozice do prvního konce řádku

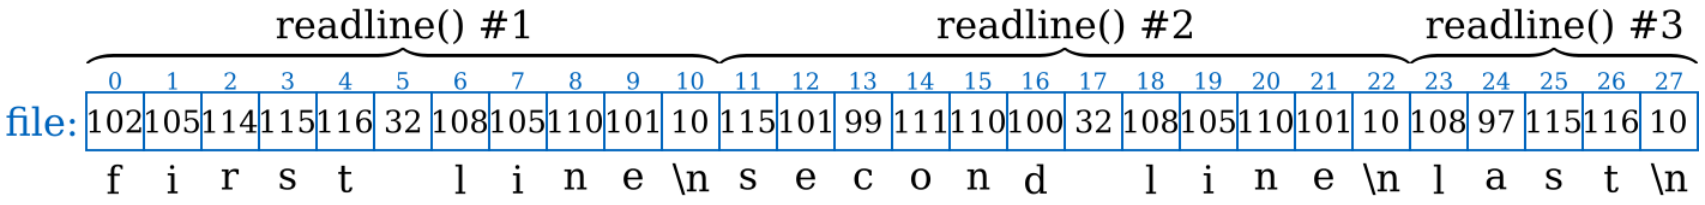


```
1 f = open("simple1.txt", "rt")
2 print('Line:',f.readline(),sep="",end="|") #1
3 print('Line:',f.readline(),sep="",end="|") #2
4 print('Line:',f.readline(),sep="",end="|") #3
5 print('Line:',f.readline(),sep="",end="|") #4
6 f.close()
```

```
Line:first line
|Line:second line
|Line:last
|Line:|
```

simple1.txt

```
first line
second line
last
```

Soubory: čtení

- Načtení všech řádků for cyklem
- For cyklus automaticky skončí po načtení posledního řádku

```
1 f = open("simple1.txt", "rt")
2 for line in f:
3     print("Line:", line, end="|")
4 f.close()
```

```
Line: first line
|Line: second line
|Line: last
|
```

simple1.txt

```
first line
second line
last
```

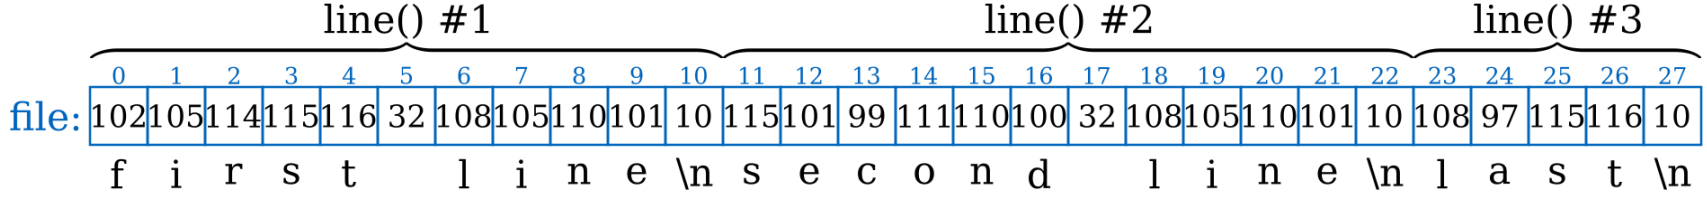

- Součástí načteného stringu je konec řádku `'\n'`

Soubory: čtení

- Načtení všech řádků for cyklem
- For cyklus automaticky skončí po načtení posledního řádku
- Hledání řetězce v souboru

```
1 fread = open("names.txt", "rt")
2 toBeFound = "Diesel"
3 numberFound = 0
4 for line in fread:
5     if line == toBeFound:
6         numberFound+=1
7 fread.close()
8 print(toBeFound,"is", numberFound, "x␣in␣the␣file")
```

```
Diesel is 0 x in the file
```

names.txt

```
Minnie
Diesel
Zara
Grace
Rudy
Diesel
Cocoa
Gucci
Belle
Diesel
Allie
Harley
Tiger
Mickey
```

- Součástí načteného stringu je konec řádku `'\n'`

Soubory: čtení

- Načtení všech řádků for cyklem
- For cyklus automaticky skončí po načtení posledního řádku
- Hledání řetězce v souboru

```
1 fread = open("names.txt", "rt")
2 toBeFound = "Diesel"
3 numberFound = 0
4 for line in fread:
5     line = line.strip()
6     if line == toBeFound:
7         numberFound+=1
8 fread.close()
9 print(toBeFound,"is", numberFound, "x␣in␣the␣file")
```

```
Diesel is 3 x in the file
```

names.txt

```
Minnie
Diesel
Zara
Grace
Rudy
Diesel
Cocoa
Gucci
Belle
Diesel
Allie
Harley
Tiger
Mickey
```

- Součástí načteného stringu je konec řádku `'\n'`
- Použijeme `line.strip()` pro jeho odstranění

Soubory: čtení

- Načtení všech řádků for cyklem
- For cyklus automaticky skončí po načtení posledního řádku
- Uložení dat do pole

```
1 f = open("simple2.txt", "rt")
2 numbers = []
3 for line in f:
4     a = int(line.strip())
5     numbers.append(a)
6 f.close()
7 print(numbers)
```

simple2.txt

```
10
20
30
4
-4
```

```
[10, 20, 30, 4, -4]
```

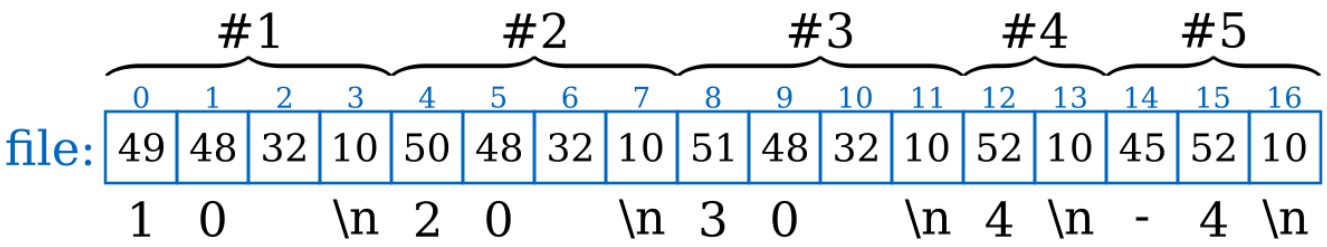

Soubory: čtení

- Konce řádků `'\n'` jsou součástí načtených řetězců
- `t.lstrip()`: vrací string, kde jsou zleva odstraněny formátovací znaky
- `t.rstrip()`: vrací string, kde jsou zprava odstraněny formátovací znaky
- `t.strip()`: kombinace `lstrip()` a `rstrip()`

t.lstrip()='some\ntext\n\n'

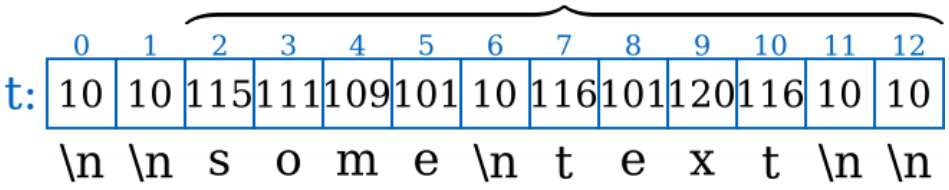

t.rstrip()='\n\nsome\ntext'

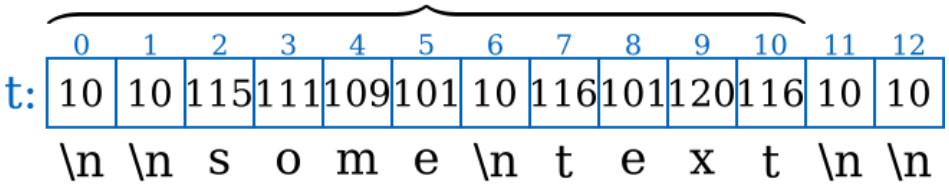

t.strip()='some\ntext'

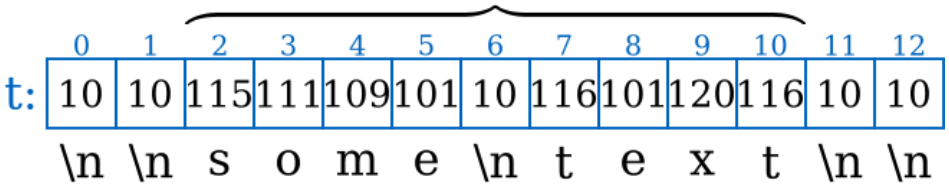

Soubory: zápis

- Otevření pro **zápis:** `f = open(jmeno_souboru, "wt")`
- “wt”— “write text”: soubor je otevřen **pro zápis**
- Pokud soubor existuje, je přepsán, jinak je vytvořen
- Do souboru zapisujeme řetězce: `f.write(text)`

```
1 f = open("someFile.txt","wt")
2 f.write("ABC")
3 f.write("def\n")
4 b = 123
5 f.write(str(b) + "␣" + str(1/7) )
6 f.close()
```

someFile.txt

```
ABCdef
123 0.14285714285714285
```

Soubory: `close()`

- Po skončení práce se souborem je dobré zavolat `close()`
- Python sice zavře všechny otevřené soubory při skončení programu, ale není to efektivní
- Počet otevřených souborů je pro každý proces omezen (1024 na Ubuntu/Linux)
- Při neuzavírání souborů se zbytečně čerpají systémové prostředky
- Nevolání `close()` může vést na chyby

```
1 f = open("someFile.txt","wt")
2 f.write("ABC")
3 f.write("def\n")
4 b = 123
5 f.write(str(b) + "␣" + str(1/7) )
6 f.close()
```

Soubory: `close()`

- Vygenerujeme náhodný počet hvězdiček, uložíme je do souboru a znovu načteme
- Porovnáme uložený řetězec a řetězec načtený ze souboru

```
1  import random
2  for i in range(8):
3      n = random.randint(1,20)
4      stars = "*" * n
5      fo = open("tempfile.txt","wt")
6      fo.write(stars)
7
8      fi = open("tempfile.txt","rt")
9      word = fi.readline().strip()
10     print("Saved:", stars, len(stars),", loaded:", word,len(word))
```

```
Saved: ** 2 , loaded:  0
Saved: ********* 9 , loaded: ** 2
Saved: ****************** 16 , loaded: ********* 9
Saved: ********* 9 , loaded: ****************** 16
Saved: *** 3 , loaded: ********* 9
Saved: ****************** 16 , loaded: *** 3
Saved: ******************** 20 , loaded: ****************** 16
Saved: ************** 14 , loaded: ******************** 20
```

Soubory: `close()`

- Používejte `close()`

```
1  import random
2  for i in range(8):
3      n = random.randint(1,20)
4      stars = "*" * n
5      fo = open("tempfile.txt","wt")
6      fo.write(stars)
7      fo.close()
8
9      fi = open("tempfile.txt","rt")
10     word = fi.readline().strip()
11     print("Saved:", stars, len(stars),", loaded:", word,len(word))
12     fi.close()
```

```
Saved: ******************** 19 , loaded: ******************** 19
Saved: *************** 15 , loaded: *************** 15
Saved: ******** 8 , loaded: ******** 8
Saved: *** 3 , loaded: *** 3
Saved: ************ 13 , loaded: ************ 13
Saved: ************ 13 , loaded: ************ 13
Saved: ********** 10 , loaded: ********** 10
Saved: **************** 15 , loaded: **************** 15
```

Soubory: doporučení

- Uvádět explicitně, jestli má být soubor otevřen pro čtení (`"rt"`) nebo zápis (`"wt"`)

```
fread = open(jmeno_souboru, "rt")
fwrite = open(jmeno_souboru, "wt")
```

- Pomáhá čtení (pochopení) programu, pomáhá při hledání chyb
- Načtení dat
  - `for line in fread: ...`
  - `line = fread.readline()` (je třeba volat opakovaně pro každý řádek)
- Odstraníme konce řádků: `line.strip()`
- Po skončení práce se souborem ho **vždy zavřeme**: `fread.close()` nebo `fwrite.close()`

Soubory: příklad

Textový soubor obsahuje postupně:

- Jeden řádek s počtem slov *n* ve skupině 1
- Jeden řádek s počtem slov *m* ve skupině 2
- *n* řádků (každý obsahuje jedno slovo)
- *m* řádků (každý obsahuje jedno slovo)

```
2
4
temple
exit
realm
nave
desire
thrust
```

```
1 fread = open("groups.txt", "rt")
2 size1 = int( fread.readline().strip() )
3 size2 = int( fread.readline().strip() )
4 for i in range(size1):
5     print("Group1:",fread.readline().strip())
6 for i in range(size2):
7     print("Group2:",fread.readline().strip())
8 fread.close()
```

```
Group1: temple
Group1: exit
Group2: realm
Group2: nave
Group2: desire
Group2: thrust
```