GNU Octave a Matlab: Řetězce

Programování F1400 + F1400a

doc. RNDr. Petr Mikulík, Ph.D.

podzimní semestr 2020

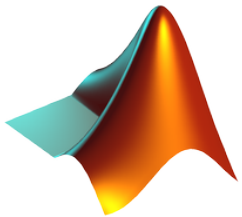

```
s = 'Hello world! Hello people! Hello you!';

% najdi vsechny vyskyty podretezce
strfind(s, 'Hello')   % presny podretezec
regexp(s, 'o.[lp]')   % regularni vyraz

% rozdel retezec na dve casti
[a,b] = strtok(s, ' ')

% rozdel na vsechny casti
v = strsplit(s, '!'),          length(v), v{1}, v{2}
w = regexp(s, 'o.l', 'split'), length(w), w{1}, w{2}
```

Vyhledávání a nahrazování v polích či maticích

- Najdi čísla dle nějaké podmínky. Logické operátory, pole či matice, příkaz `find`.
- Vygenerujeme řadu prvočísel, najdeme ta v rozsahu 10–20, a zjistíme jejich počet.

```
octave> a = primes(40)          ... vygeneruj prvočísla do 40
a =
    2    3    5    7   11   13   17   19   23   29   31   37

octave> (a>=10 & a<=20)         ... která jsou v zadaném rozsahu od 10 do 20?
ans =
  0  0  0  0  1  1  1  1  0  0  0  0

octave> a(a>=10 & a<=20)        ... najdi (vypiš) je
ans =
  11   13   17   19

octave> find(a>=10 & a<=20)     ... nalezení jejich indexů v poli a
ans =
   5   6   7   8

octave> sum(a>=10 & a<=20)      ... kolik jich je? sečtením jedniček
ans =  4

octave> length(find(a>=10 & a<=20))  ... kolik jich je? délka pole s nalezenými
ans =  4
```

Znaky (characters, chars)

- **Znak:** 1 bajt, tedy celé číslo bez znaménka, tedy v rozsahu [0; 255].
- Dříve pouze 7 bitů z 8 neslo znak, osmý bit byl „paritní“.
- Který znak dané číslo reprezentuje (číslo, písmeno, interpunkce, odřádkování a další tisknutelné a netisknutelné znaky): současný standard pro [0; 127] udává tabulka **ASCII** (American Standard Code for Information Interchange), viz následující strana.
- **Národní znaky (např. akcenty, azbuka)** – pozice 128 až 255 dle národních kódování (např. standardy ISO Latin 1, ISO Latin 2, další „code pages“ např. DOS CP 852 nebo Windows CP 1250), avšak nelze umístit ani všechny evropské znaky.
- Proto se nyní používá standardizované vícebajtové kódování podle normy **Unicode** (konkrétně kódování UTF-8, UTF-16, UTF-32), viz v LaTeXu příkaz `inputenc{utf8x}`, pro programování řetězců je ale práce s Unicode obtížnější než s řetězci tvořenými pouze jednobajtovými znaky.

Znaky (characters) a ASCII tabulka (7 bitů)

Dec	Hex	Oct	Char	Description	C
0	0	000	NUL	null	
1	1	001	SOH	start of heading	
2	2	002	STX	start of text	
3	3	003	ETX	end of text	
4	4	004	EOT	end of transmission	
5	5	005	ENQ	enquiry	
6	6	006	ACK	acknowledge	
7	7	007	BEL	bell	\a
8	8	010	BS	backspace	\b
9	9	011	TAB	horizontal tab	\t
10	A	012	LF	line feed, new line	\n
11	B	013	VT	vertical tab	\v
12	C	014	FF	form feed, new page	
13	D	015	CR	carriage return	\n
14	E	016	SO	shift out	
15	F	017	SI	shift in	
16	10	020	DLE	data link escape	
17	11	021	C1	device control 1	
18	12	022	C2	device control 2	
19	13	023	C3	device control 3	
20	14	024	C4	device control 4	
21	15	025	NAK	negative acknowledge	
22	16	026	SYN	synchronous idle	
23	17	027	ETB	end of trans. block	
24	18	030	CAN	cancel	
25	19	031	EM	end of medium	
26	1A	032	SUB	substitute	
27	1B	033	ESC	escape	
28	1C	034	FS	file separator	
29	1D	035	GS	group separator	
30	1E	036	RS	record separator	
31	1F	037	US	unit separator	

Dec	Hex	Oct	Char
32	20	040	Space
33	21	041	!
34	22	042	"
35	23	043	#
36	24	044	$
37	25	045	%
38	26	046	&
39	27	047	’
40	28	050	(
41	29	051	)
42	2A	052	*
43	2B	053	+
44	2C	054	,
45	2D	055	-
46	2E	056	.
47	2F	057	/
48	30	060	0
49	31	061	1
50	32	062	2
51	33	063	3
52	34	064	4
53	35	065	5
54	36	066	6
55	37	067	7
56	38	070	8
57	39	071	9
58	3A	072	:
59	3B	073	;
60	3C	074	<
61	3D	075	=
62	3E	076	>
63	3F	077	?

Dec	Hex	Oct	Char
64	40	100	@
65	41	101	A
66	42	102	B
67	43	103	C
68	44	104	D
69	45	105	E
70	46	106	F
71	47	107	G
72	48	110	H
73	49	111	I
74	4A	112	J
75	4B	113	K
76	4C	114	L
77	4D	115	M
78	4E	116	N
79	4F	117	O
80	50	120	P
81	51	121	Q
82	52	122	R
83	53	123	S
84	54	124	T
85	55	125	U
86	56	126	V
87	57	127	W
88	58	130	X
89	59	131	Y
90	5A	132	Z
91	5B	133	[
92	5C	134	\
93	5D	135	]
94	5E	136	^
95	5F	137	_

Dec	Hex	Oct	Char
96	60	140	‘
97	61	141	a
98	62	142	b
99	63	143	c
100	64	144	d
101	65	145	e
102	66	146	f
103	67	147	g
104	68	150	h
105	69	151	i
106	6A	152	j
107	6B	153	k
108	6C	154	l
109	6D	155	m
110	6E	156	n
111	6F	157	o
112	70	160	p
113	71	161	q
114	72	162	r
115	73	163	s
116	74	164	t
117	75	165	u
118	76	166	v
119	77	167	w
120	78	170	x
121	79	171	y
122	7A	172	z
123	7B	173	{
124	7C	174	|
125	7D	175	}
126	7E	176	∼
127	7F	177	DEL

Znaky (characters, chars)

- **Znaky:** používejme písmena bez diakritiky, pak lze volně přecházet mezi číselným a „obrázkovým“ vyjádřením znaku:

```
octave> c = 66;
octave> fprintf('Znak s ASCII kodem %i je %c\n', c, c);
znak s ascii kodem 66 je B
```

- Znaky v C – oblíbené funkce z knihovny `ctype.h` – výběr podmnožin ASCII tabulky:

```
islower(); isupper();
isspace(); isblank();
isdigit(); isxdigit();
isalnum(); isalpha(); isascii();
iscntrl(); isgraph();
isprint(); ispunct();

tolower(); toupper();   ...   Matlab: lower(), upper()
toascii();
```

- V C lze míchat reprezentaci znaků číslem a syntaxí s apostrofy (např. `'B'`), zatímco v GNU Octave/Matlab se k tomu používají řetězce.
- Funkce z ctype.h jsou v GNU Octave dostupné pro řetězce. V Matlabu jsou dostupné jen některé z nich a to ještě pod jinými názvy :-(

Řetězce

- **Řetězec** – posloupnost znaků, tj. pole či vektor znaků.
- Jazyk C a Unixová implementace řetězců: řetězec je posloupnost znaků ukončená číslem nula. Céčko: funkce pro práci s řetězci jsou v knihovně `string.h`.
- Většina jazyků: řetězce se zadávají v **uvozovkách**.
  Matlab a GNU Octave: řetězce se zadávají v **apostrofech** (ale GNU Octave akceptuje i uvozovky).
- **Naplnění a vypsání řetězce:**

```
octave> s = 'Hello world'
s = Hello world

octave> fprintf('Pozdrav je: %s.\n', s);
Pozdrav je: Hello world.

octave> length(s)                ... jednoznačná délka, pokud nejsou nabodeníčka
ans =  11
```

- **Naplnění řetězce formátováním proměnných** – příkaz `sprintf()`:

```
m = 2;
s = sprintf('Cislo pi krat %i se rovna %.16g', m, m*pi)

=> s = Cislo pi krat 2 se rovna 6.283185307179586
```

Řetězce – přístup k prvkům

- **Řetězec** – posloupnost znaků, tj. pole či vektor znaků – přístup k prvkům (znakům) je tedy stejný jako u číselných vektorů.
- **Přístup k jednotlivým znakům** řetězce – příklad:

```
octave> s = 'Hello.'; s(1)='X', s(end)='!'
s = Hello.
s = Xello.
s = Xello!
```

- Příklad – **výpis všech znaků řetězce**:

```
s = 'Hello world!'
fprintf('Retezec "%s" ma %i znaku.\n', s, length(s));
for k=1:length(s)
    fprintf('Znak cislo %2i je: %3i ... %c\n', k, s(k), s(k));
end

=>
Znak cislo  1 je:  72 ... H
Znak cislo  2 je: 101 ... e
Znak cislo  3 je: 108 ... l
Znak cislo  4 je: 108 ... l
Znak cislo  5 je: 111 ... o
...
```

Základní funkce s řetězci

- **Změna malých a velkých písmen**; mezery a číslice: **vyhledání**

```
octave> s = 'Hello World 123'
s = Hello World 123

octave> upper(s), lower(s)
ans = HELLO WORLD 123
ans = hello world 123

octave> islower(s), isupper(s)
ans =
  0  1  1  1  1  0  0  1  1  1  1  0  0  0  0
ans =
  1  0  0  0  0  0  1  0  0  0  0  0  0  0  0

octave> find(islower(s)), find(isupper(s))
ans =
    2    3    4    5    8    9   10   11
ans =
   1   7

octave> isspace(s), isdigit(s)
ans =
  0  0  0  0  0  1  0  0  0  0  0  1  0  0  0
ans =
  0  0  0  0  0  0  0  0  0  0  0  0  1  1  1
```

Manipulace se znaky v řetězcích – cyklem

- **Manipulace cyklem** – konverze řetězce na malá písmena (různé verze, stejný výsledek; vzdálenost písmen a a A je 32):

```
s = 'Hello World 123';
for k=1:length(s)
    if (s(k)>='A' && s(k)<='Z') s(k) = s(k) + 32; end
    % nebo:  if (s(k)>='A' && s(k)<='Z') s(k) = lower(s(k)); end
    % nebo:  if (s(k)>='A' && s(k)<='Z') s(k) = tolower(s(k)); end
    % nebo:  if (isupper(s(k))) s(k) = tolower(s(k)); end
end
s

=> s = hello world 123
```

- **Manipulace cyklem** – výměna malých písmen za velká a malých za velká:

```
s = 'Hello World 123';
for k=1:length(s)
    if (islower(s(k)))          % nebo:  (s(k)>='a' && s(k)<='z')
        s(k) = upper(s(k));     %  nebo: s(k) = s(k) - 32
    elseif (isupper(s(k)))      % nebo:  (s(k)>='A' && s(k)<='Z')
        s(k) = lower(s(k));     %  nebo: s(k) = s(k) + 32
    end
end
s

=> s = hELLO WORLD 123
```

Manipulace se znaky v řetězcích – vektorově

- **Vektorová verze** – výměna mezer za podtržítka:

```
octave> s = 'Hello World 123';
octave> ss=s; ss(isspace(s)) = '_'
ss = Hello_World_123
```

- **Vektorová verze** – smazání mezer:

```
octave> s = 'Hello World 123';
octave> ss=s; ss(isspace(s)) = []
ss = HelloWorld123
```

- **Vektorová verze** – konverze řetězce na malá písmena (dvě verze):

```
lower(s)
s(s>='A' & s<='Z') = s(s>='A' & s<='Z') + 32
```

- **Vektorová verze** – výměna malých písmen za velká a malých za velká:

```
s = 'Hello World 123';
ss = s;
s(ss>='A' & ss<='Z') = s(ss>='A' & ss<='Z') + 32
s(ss>='a' & ss<='z') = s(ss>='a' & ss<='z') - 32

=> s = hELLO WORLD 123
```

Setřídění znaků v řetězci, čtení čísla a řetězce z klávesnice

- **Setřídění** písmen v řetězci, a to včetně výpisu, na které pozici původního řetězce se utříděné znaky nacházely – příkaz `sort()`:

```
s = 'Hello World 123';
octave> sort(s)
ans =   123HWdellloor

octave> [ss,ind] = sort(s)
ss =   123HWdellloor
ind =
    6   12   13   14   15    1    7   11    2    3    4   10    5    8    9
```

- **Načtení čísla a řetězce z klávesnice:** – příkaz `input()`:

```
octave> x = input('Zadej cislo: ')
Zadej cislo: 123.45
x =  123.45

octave> s1 = input('Zadej řetězec: ', 's')
Zadej řetězec: Ahoj nazdar!
s1 = Ahoj nazdar!
```

Podřetězce

- **Vyhledání podřetězců:**

```
octave> s = 'Hello world! Hello people! Hello you!';
octave> strfind(s, 'Hello')
ans = 1   14   28
octave> index(s, 'Hello')
ans =  1
```

- **Rozřezávání řetězců (tokens):**

```
octave> s = 'Hello world! Hello people! Hello you!';
octave> [a,b] = strtok(s, ' ')
a = Hello
b =  world! Hello people! Hello you!
octave> j = index(b, '!'), d = b(j+2:end)
j =  7
d = Hello people! Hello you!
```

- **Rozřezávání řetězců (split):**

```
octave> s = 'Hello world! Hello people! Hello you!';
octave> z = strsplit(s, '!'), length(z), z{2}
z = {
  [1,1] = Hello world
  [1,2] =  Hello people
  [1,3] =  Hello you
  [1,4] =
}
ans =  4
ans =  Hello people
```

Porovnávání řetězců

- Porovnávání řetězců – příkaz `strcmp()`:

```
octave> a = 'ahoj', b = 'nazdar', c = 'ahoj', d = 'AHOJ'
octave> strcmp(a,b), strcmp(a,c), strcmp(a,d)
ans = 0                 ... řetězce jsou různé
ans = 1                 ... řetězce jsou stejné
ans = 0                 ... řetězce jsou různé
```

- Porovnávání řetězců bez ohledu na velikost písmen – příkaz `strcmpi()`:

```
octave> a = 'ahoj', b = 'nazdar', c = 'ahoj', d = 'AHOJ'
octave> strcmpi(a,b), strcmpi(a,c), strcmpi(a,d)
ans = 0                 ... řetězce jsou různé
ans = 1                 ... řetězce jsou stejné
ans = 1                 ... stejné, velká a malá písmena ignorována
```

- *Poznámka: v jazyce C dává funkce* `strcmp()` *tři hodnoty: 0 pro případ shody, a* ± 1 *podle toho, který řetězec je abecedně dříve.*

Řetězce se znaky s diakritikou

- České a další ne-anglické texty mohou obsahovat znaky s diakritikou např. „žlutý kůň“. Ty musí být reprezentovány 8bitovým rozšířením 7bitového ASCII nebo vícebajtovou sadou Unicode. Co vzít za délku takovéhoto řetězce? Octave pracuje v UTF-8 a vypíše počet bajtů, Matlab pracuje v UTF-16 a vypíše počet znaků:

```
s='Příliš žluťoučký kůň úpěl ďábelské ódy.', length(s)
```

- Řešení pro zpracování českých textů: převeďte řetězec do jednobajtového kódování: `unicode2native(s, encoding)`, kde encoding může být `ascii`, `latin2`, `cp1250`, `cp850`, `cp852`, apod.
(Poznámka: za encoding můžete dosadit i `utf-16` a zpracovávat vektor po dvojicích čísel.)

```
% s='Příliš žluťoučký kůň úpěl ďábelské ódy.'
s='kůň'
z=unicode2native(s, 'ascii')
length(s), length(z)
z(1)='x', zz=sprintf('%c', z)

z=unicode2native (s, 'latin2')
length(s), length(z)
z(1)='x'
z2=native2unicode(z,'latin2')
zz=sprintf('%c', z2)
```

Regulární výrazy

- **Regulární výrazy – regular expressions**, česky též **výrazy se zástupnými znaky** – umožňují hledat více (podobných) řetězců současně.
- Tečka odpovídá libovolnému znaku: A.B → A@B, AAB, ABB, AzB, A0B, ...
  Výčet znaků v hraných závorkách: A[xyz]B → AxB, AyB, AzB
  Dále – pro posloupnost, * pro opakování, ? a {...} pro počet opakování, aj.
- **Příklady použití:**

```
octave> s = 'Hello world! Hello people!'
octave> regexp(s, 'o')                    ... funguje stejně jako strfind()
=>      ans = 5    8   18   22
octave> regexp(s, 'o[rp]')                ... hledá všechna o následovaná r či p
=>      ans = 8   22
octave> regexp(s, 'o.l')                  ... hledá o, pak jakýkoliv znak, pak l
=>      ans = 8   22
octave> regexp(s,'o*p'),  regexp(s,'o.*p') ... povoleno vícenásobné opakování
=>      ans = 20 22       ans = 5
octave> regexp(s, 'o.l', 'split')         ... rozřezání řetězce na části
=>      ans = {
          [1,1] = Hello w
          [1,2] = d! Hello pe
          [1,3] = e!
        }
```