# Regulární výrazy prakticky

Martin Bruchanov — bruxy@regnet.cz

5. října 2013

# Co, jak a proč?

„*Regulární výraz* je vzor, který udává množinu řetězců znaků; říká jak mají vypadat odpovídající řetězce.“ — Ken Thompson, autor editoru QED

- Možná znáte:
  - Vzory v názvech souborů: `*.*`, `*.jpg`, `???.*`, `...`
  - Vzory v SQL dotazech:

    ```
    SELECT * FROM tabulka WHERE name LIKE 'a%' and 'z_';
    ```
  - Popis syntaxe programovacích jazyků Backusova–Naurova Forma (BNF): `n ::= {_|A..Z|a..z}`, `d ::= {0..9}`, `id ::= n,{n,d}`
- Čím se budeme zabývat:
  - Viz `man 7 regex` – regulární výrazy POSIX (regex, RE)
  - základní (BRE) / rozšířené (ERE)
  - `grep, sed, awk, vi, vim, bash`
  - `perl, python`

# Metaznaky

- `.` (tečka) – libovolný znak (kromě „\n“)
- `[...]`/`[^...]` – množina/negovaná množina znaků
- `^`/`$` – začátek/konec řádku nebo řetězce
- `\(...\)`/`(...)` – seskupení výrazu (atom) BRE/ERE
- `\|`, `|` – nebo, alternativní výrazy (ERE)
- `\n` – $n$-tý zachycený podvýraz
- Další častá rozšíření:
  - `&` – poslední nahrazený řetězec (sed, ViM)
  - `\<` / `\>` – začátek/konec slova

# Příklad 1.: Test názvu proměnné (indentifikátoru) v jazyce C.

Název proměnné v jazyce C může obsahovat malé a velké znaky anglické abecedy, podtržítko a číslo. Název proměnné nesmí začínat číslem.
Z referenční příručky jazyka C:

```
nondigit ::= {_|A..Z|a..z}
digit    ::= {0..9}
identifier ::= nondigit,{nondigit|digit}
```

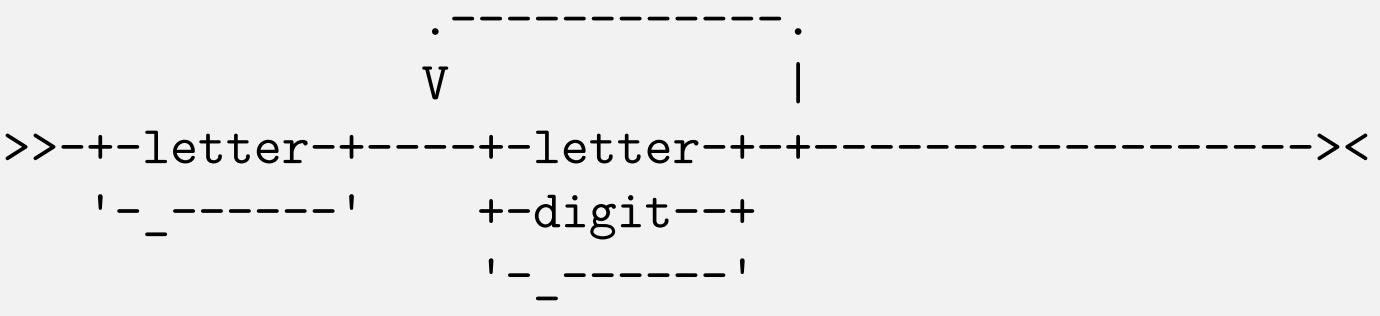

# Příklad 1.: Regulární výraz

- `^[A-Za-z_][A-Za-z_0-9]*$`
- `^[[:alpha:]_][[:word:]]*$`

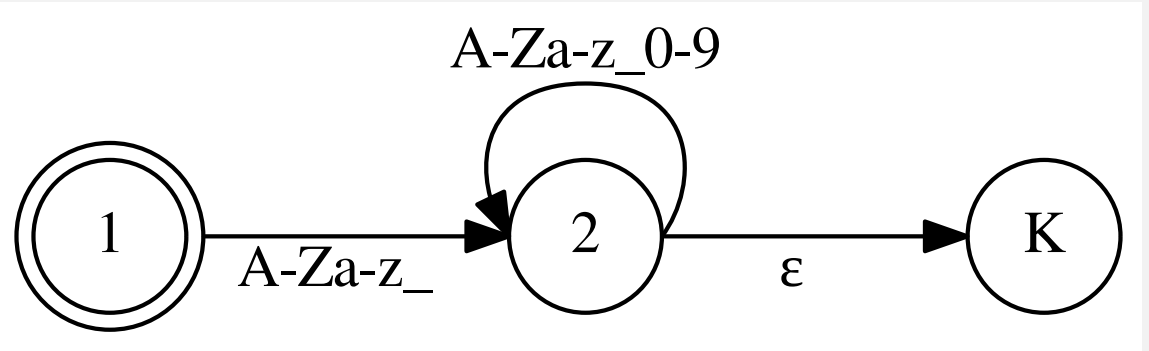

# Kvantifikátory

| Stand. | Líný | Rozsah |
|---|---|---|
| `*` | `*?` | 0 a víc |
| `+` | `+?` | 1 a víc (ERE) |
| `?` | `??` | 0 nebo 1 položka (ERE) |
| `{n}` | `{n}?` | přesně $n\times$ |
| `{n,}` | `{n,}?` | minimálně $n\times$ |
| `{n,m}` | `{n,m}?` | min. $n\times$ a max. $m\times$. |

**Příklady:**

- `a*b` – aabc abc bc
- `a?b` – aabc abc bc
- `a+b` – aabc abc bc
- `[els]{1,3}` – all in the darkness
- `Pe(t|p)a` – Pera Peta Pepa
- `".*"` – "Ahoj" "Hello"
- `"[^"]*"` – "Ahoj" "Hello"

- Pozor na rozdíl Basic-RE: `\{m,n\}`, Extended-RE: `{m,n}`
- Líná varianta pochází z Perlu.

# Množiny

| Meta | POSIX | Unicode | Množina | Popis |
|---|---|---|---|---|
| `\d` | `[:digit:]` | `\p{IsDigit}` | `[0-9]` | Číslice |
| `\D` | | `\P{IsDigit}` | `[^0-9]` | Cokoliv mimo číslici |
| `\s` | `[:space:]` | `\p{IsSpace}` | `[ \t\n\r\f]` | Bílý znak |
| `\S` | | `\P{IsSpace}` | `[^ \t\n\r\f]` | Cokoliv mimo bílého znaku |
| `\w` | `[:word:]` | `\p{IsWord}` | `[a-zA-Z0-9_]` | Znaky identifikátorů |
| `\W` | | `\P{IsWord}` | `[^a-zA-Z0-9_]` | Cokoliv mimo znaků identifikátorů |
| `\b` | | | | hranice slova, opakem je `\B` |
| | `[:alnum:]` | `\p{PosixAlnum}` | `[A-Za-z0-9]` | Alfanumerické znaky |
| | `[:xdigit:]` | `\p{PosixXDigit}` | `[A-Fa-f0-9]` | Hexadecimální čísla |
| | `[:print:]` | `\p{PosixPrint}` | `[\x20-\x7E]` | Tisknutelné znaky |
| | `[:alpha:]` | `\p{PosixAlnum}` | `[A-Za-z]` | Abecední znaky |

# Porovnání nástrojů

| | grep/sed | grep -E | awk | vim | Perl |
|---|---|---|---|---|---|
| **znaky** | | | | | |
| libovolný znak (mimo \n) | . | . | . | . | . |
| množina znaků | [ ] | [ ] | [ ] | [ ] | [ ] |
| kromě těchto znaků | [^ ] | [^ ] | [^ ] | [^ ] | [^ ] |
| **opakování** | | | | | |
| libovolný počet | * | * | * | * | * *? |
| alespoň jeden | \+ | + | + | \+ | + +? |
| nanejvýš jeden | \? | ? | ? | \? \= | ? ?? |
| přesně $n\times$ | \{n\} | {n} | {n} | \{n} | {n} |
| minimálně | \{min,\} | {min,} | {min,} | \{min,} | {min,} |
| min až max | \{min,max\} | {min,max} | {min,max} | \{min,max} | {min,max} |
| **pozice** | | | | | |
| začátek řádku | ^ | ^ | ^ | ^ | ^ |
| konec řádku | $ | $ | $ | $ | $ |
| začátek slova | \< | \< | \< \y | \< | \A \b |
| konec slova | \> | \> | \> \y | \> | \z \b |
| **závorky a paměť** | | | | | |
| skup. se zapamatováním | \( \) | ( ) | | \( \) | ( ) |
| skupina bez paměti | | | ( ) | | (?: ) |
| třetí zapamatovaný | \3 | \3 | \3 | \3 | $3 \3 |

# Neinteraktivní proudový editor sed

- K čemu a jak to funguje? (Podpora UTF-8.)
- `sed [-n] -e '`*`příkaz`*`[;`*`příkaz`*$_2$`]' [-f `*`skript`*`] `*`vstup(y)`*
- Nahrazování (s):
  `sed s/vzor/náhrada/flag < vstup.txt > vystup.txt`
  Flagy: `g` – vše pokryté regexem, $n$ – pořadí výskytu v řádku
- Rozsah: `'1,10 `*`příkaz`*`'`, do konce `'10,$ `*`příkaz`*`'`
- Vypsání části (p): `sed -n '5,$p' vstup.txt`
- Vyhledávání: `sed -n '/regex/p' vstup.txt`
- Náhrada znaků (y): `y/ěščřžýáíé/escrzyaie/`
- Vymazání řádků (d): `'/^[[:blank:]]*#/d'`, `'/^$/d'`
- Vlož před řádek (i): `'1i\text'` před první řádek vlož „text“
- Vlož za řádek (a): `'$a\konec'` za poslední vlož „konec“

# GNU Bourne-Again SHell

```
1 #!/bin/bash
2 name="LinuxDays2013"
3 if [[ $name =~ L[a-zA-Z]*([0-9]+) ]]
4 then
5     echo ${BASH_REMATCH[1]}
6 fi
```

- Podpora od verze 3.x (`$BASH_VERSION`)
- `$BASH_REMATCH`, `${BASH_REMATCH[0]}` – celý řetězec
- `${BASH_REMATCH[1]}` – podskupina „jedno a více čísel“

# Perl

```perl
#!/usr/bin/env perl

$name = "LinuxDays2013";

if ( $name =~ m/L[a-zA-Z]*([0-9]+)/ ) {
    print $1 . "\n"
}
```

- (PCRE) Perl Compatible Regular Expression
- Zpětná reference se provádí pomocí $\$n$
- Operátor `m/`*`regex`*`/`*`flagy` vrací true při nalezení
- Nahrazení `$name =~ s/Linux/Windows/;` (zpětná ref. $\backslash n$)

# Python

```
1 #!/usr/bin/env python
2 import re
3 name = "LinuxDays2013"
4
5 match = re.match(r'L[a-zA-Z]*([0-9]+)', name)
6 if match:
7     print match.group(1)
```

- Podpora perlovského stylu regexů
- Použijte surové řetězce `r'`*regex*`'` (problém escape-sekvence)
- `object = re.match(`*regex, vstup[, flagy]*`)`