**Tópicos Especiais em Fundamentos da Computação**
**Shell Scripting**

# Expressões Regulares

Andrei Rimsa Álvares
andrei@cefetmg.br

# Sumário

- Introdução
- `grep`
- Expressões regulares
- Regra
- Substituição de texto
- Expressões regulares estendidas

# INTRODUÇÃO

# Introdução

- De forma simples, expressões regulares são notações usadas para identificar padrões em textos
  - De certa forma, parecem com o sistema de caracteres coringas de expansão de arquivos, mas em uma escala bem maior

- Expressões regulares definem um conjunto de uma ou mais strings
  - Uma string simples é uma expressão regular que define uma string: ela mesma
  - Uma expressão regular complexa usa letras, números e caracteres especiais para definir muitas diferentes strings

Uma expressão regular casa com qualquer string que ela define

# Onde Usar Expressões Regulares?

- Expressões regulares são suportadas por vários programas em linha de comando e por muitas linguagens de programação para facilitar a resolução de problemas de manipulação de textos

sed

vim

ed

awk

emacs

perl

**Cuidado:** nem todas expressões regulares funcionam da mesma forma, podem variar de ferramentas e LPs

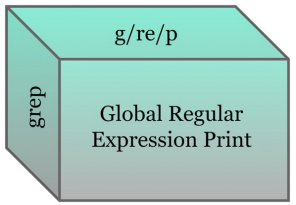


grep

# GREP

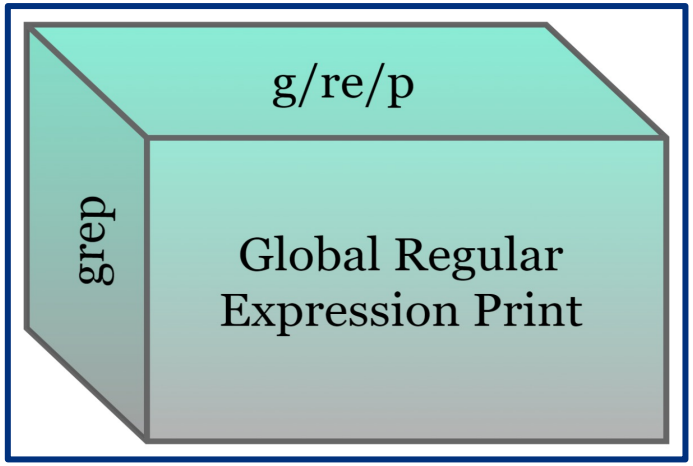

# grep

- O programa principal que será usado para demonstrar o uso das expressões regulares será o `grep`♠
  - Em essência, esse programa procura em arquivos de texto pela ocorrência de expressões regulares especificadas e imprime qualquer linha que casa na saída padrão

- Até agora, `grep` foi usado somente para buscar *strings* fixas

```
$ ls /usr/bin | grep zip
bunzip2
bzip2
gunzip
gzip
unzip
…
```

♠: *global regular expression print*

# grep

- `grep` possui a seguinte sintaxe

```
grep [options] regex [file...]
```

, tal que *regex* é uma expressão regular

- A tabela a seguir mostra algumas opções comumente utilizadas

| Opção | Descrição |
|---|---|
| `-i` | Ignora caixa, não distingue entre caracteres maiúsculos e minúsculos |
| `-v` | Inverter o casamento, mostra todas as linhas que não contém o casamento |
| `-c` | Mostra o número de casamentos (ou não-casamentos no caso de –v) |
| `-l` | Mostra os nomes do arquivos que contém o casamento, ao invés das linhas |
| `-L` | Similar a opção –l, mas que mostra os arquivos que não contém casamentos |
| `-n` | Prefixa cada linha casada com o número da linha |
| `-h` | Para pesquisa com múltiplos arquivos, suprime o nome do arquivo na saída |

# Exemplos

- Antes de mostrar exemplos, criar vários arquivos com dados

```
$ ls /bin > dirlist-bin.txt
$ ls /usr/bin > dirlist-usr-bin.txt
$ ls /sbin > dirlist-sbin.txt
$ ls /usr/sbin > dirlist-usr-sbin.txt
$ ls dirlist*.txt
dirlist-bin.txt        dirlist-usr-bin.txt
dirlist-sbin.txt       dirlist-usr-sbin.txt
```

- Exemplos

```
$ grep bzip dirlist*.txt
dirlist-usr-bin.txt:bzip2
dirlist-usr-bin.txt:bzip2recover
```

```
$ grep -l bzip dirlist*.txt
dirlist-usr-bin.txt
```

```
$ grep -L bzip dirlist*.txt
dirlist-bin.txt
dirlist-sbin.txt
dirlist-usr-sbin.txt
```

# EXPRESSÕES REGULARES

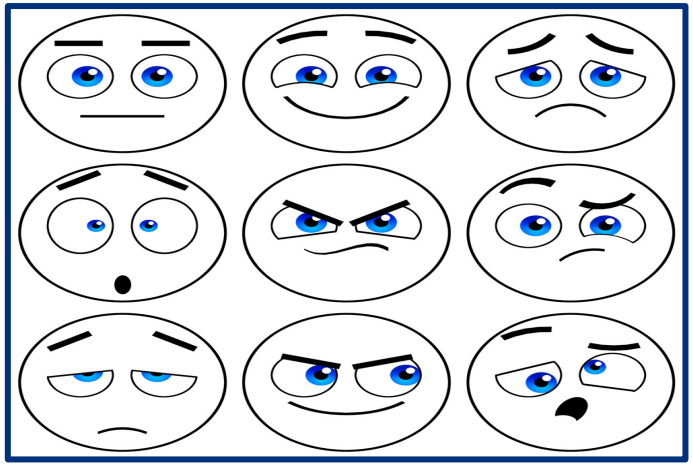

Shell Scripting

# Caracteres

- Um caractere é considerado qualquer um que não seja nova linha (\n)
  - **Caracteres literais:** caracteres que se representam (casam eles próprios)
  - **Caracteres especiais (*metacaracteres*):** caracteres que são usados para representar casamentos mais complexos; são eles
    - Expressão regular básica: `^ $ . [ ] * \`
    - Expressão regular estendida: `? + ( ) { } |`

**Dica:** se precisar usar um caractere especial para representar a si próprio, deve-se escapá-lo

# Delimitadores

- Um caractere chamado delimitador usualmente marca o início e o fim de uma expressão regular
- O delimitador é sempre um caractere especial para a expressão regular que ele delimita (não representa a si próprio)
- Algumas ferramentas (como vim) permitem o uso de outros caracteres como delimitadores, enquanto `grep` não usa delimitador nenhum
  - Aqui será usado a barra normal (/) como delimitador
- Em alguns casos não ambíguos, o segundo delimitador não é necessário; pode ser omitido se for imediatamente seguido por RETURN

# *Strings* Simples

- A expressão regular mais básica é uma *string* simples que não contém nenhum caractere especial, a não ser os delimitadores
  - Uma *string* simples casa somente ela mesmo

| Expressão Regular | Casamento | Exemplos |
|---|---|---|
| `/ring/` | **ring** | **ring**, sp**ring**, **ring**ing, st**ring**ing |
| `/Thursday/` | **Thursday** | **Thursday**, **Thursday**'s |
| `/or not/` | **or not** | **or not**, poo**r not**hing |

# Caracteres Especiais

- Os caracteres especiais são
  - **Ponto ( . ):** o ponto casa qualquer (um) caractere
  - **Colchetes ([]):** os colchetes definem uma classe de caracteres, que casa qualquer caractere único dessa classe; ^ casa qualquer caractere não especificado na classe, enquanto – pode definir uma faixa de caracteres
  - **Asterisco (*):** o asterisco representa zero ou mais ocorrências de um casamento de expressão regular precedente
  - **Âncoras (^ e $):** uma expressão regular que começa com ^ casa apenas strings no começo da linha, enquanto $ casa no final
  - **Escapes (\):** pode-se escapar qualquer caractere especial (mas não parênteses ou dígitos) colocando uma barra invertida antes

# Ponto ( . )

- Um ponto casa qualquer (um) caractere

| Expressão Regular | Casamento | Exemplos |
|---|---|---|
| / .alk/ | espaço + qualquer caractere + alk | will **talk**, may **balk** |
| /.ing/ | qualquer caractere + ing | **sing** song, **ping**, before **ing**lenook |

- Exemplo

```
$ grep -h '.zip' dirlist*.txt
bunzip2
bzip2
bzip2recover
funzip
gunzip
gzip
unzip
unzipsfx
```

# Colchetes ([])

- Define uma classe de caracteres, que casa qualquer caractere único dessa classe
  - Circunflexo (^) casa qualquer caractere não especificado na classe
  - Hífen (–) pode definir uma faixa de caracteres

| Expressão Regular | Casamento | Exemplos |
|---|---|---|
| `/[bB]ill/` | b ou B + ill | **bill**, **Bill**, **bill**ed |
| `/t[aeiou].k/` | t + qualquer vogal + qualquer caractere + k | **talk**ative, s**tink**, **teak**, **tank**er |
| `/# [6-9]/` | # seguido de espaço + dígitos entre 6 e 9 | **# 6** 0, **# 8**, get **# 9** |
| `/[^a-zA-Z]/` | Qualquer caractere que não é uma letra | **1**, **7**, **@**, **.**, **}**, Stop**!** |

**Cuidado:** barra invertida (\) e asterisco (*) perdem seu significado especial entre colchetes

# Colchetes ([])

- Exemplos
  - b ou g seguidos de zip

```
$ grep -h '[bg]zip' dirlist*.txt
bzip2
bzip2recover
gzip
```

  - Qualquer caractere diferente de b ou g seguidos de zip

```
$ grep -h '[^bg]zip' dirlist*.txt
bunzip2
funzip
gunzip
unzip
unzipsfx
```

  - Contém uma letra maiúscula

```
$ grep -h '[A-Z]' dirlist*.txt
BuildStrings
CpMac
DeRez
GetFileInfo
HsColour
...
```

O que [-AZ] faz?

# Colchetes ([])

- Classes de caracteres pré-definidas

| Classe | Significado |
|---|---|
| `[:alnum:]` | Caracteres alfanuméricos: letras e dígitos |
| `[:alpha:]` | Caracteres do alfabeto: letras |
| `[:blank:]` | Caracteres branco: espaço em branco e tabulação |
| `[:cntrl:]` | Caracteres de controle (CONTROL) |
| `[:digit:]` | Caracteres numéricos: dígitos |
| `[:graph:]` | Caracteres gráficos: **[:alnum:]** e **[:punct:]** |
| `[:lower:]` | Caracteres minúsculos do alfabeto: **[a-z]** |
| `[:print:]` | Caracteres imprimíveis: **[:alnum:]**, **[:punct:]** e **[:space:]** |
| `[:space:]` | Caracteres de espaçamento: espaço, tabulação, nova linha, *form feed* e *carriage return* |
| `[:upper:]` | Caracteres maiúsculos do alfabeto: **[A-Z]** |
| `[:xdigit:]` | Dígitos hexadecimais: **[0-9]**, **[a-f]** e **[A-F]** |

# Asterisco (*)

- O asterisco representa zero ou mais ocorrências da expressão regular **precedente**
  - Asterisco depois de um caractere literal indica zero ou mais sequências desse caractere
  - Asterisco depois de ponto (.) casa qualquer sequência de caracteres
  - Asterisco depois de uma classe de caracteres casa qualquer string cujos caracteres são membros da classe

# Asterisco (*)

| Expressão Regular | Casamento | Exemplos |
|---|---|---|
| /ab*c/ | a + zero ou mais b's + c | **ac**, **abc**, **abbc**, debbca**abbbc** |
| /ab.*c/ | ab + qualquer sequência de caractes + c | **abc**, **abxc**, **ab45c**, x**ab 765.345 x c**at |
| /t.*ing/ | t + qualquer sequência de caracteres + ing | **thing**, **ting**, I **thought of going** |
| /[a-zA-Z ]*/ | Strings compostas por letras (maiúsculas e minúsculas) e espaço | 1. **any string without numbers or punctuation**! |
| /(.*)/ | A maior string entre ( e ) | Get **(this) and (that)**; |
| /([^)]*)/ | A menor string entre ( e ) | **(this)**, Get **(this and that)** |

- Exemplo

```
$ cat dirlist-* | grep "uu.*e"
uudecode
uuencode
uuidgen
uuname
uusched
```

# Âncoras (^ e $)

- Uma expressão regular que começa com um circunflexo (^) casa apenas strings no começo da linha; já o sinal de dólar ($) no final da expressão regular casa no final da linha

| Expressão Regular | Casamento | Exemplos |
|---|---|---|
| /^T/ | Um T no começo da linha | **T**his line,<br>**T**hat time,<br>In Time |
| /^+[0-9]/ | Um sinal de mais (+) seguido de um dígito no começo da linha | **+5** +45.72,<br>**+7**59 Keep this... |
| /:$/ | Um dois pontos no final da linha | ...below**:** |

**Curiosidade:** ^ e $ são chamadas de âncoras porque forçam (ancoram) um casamento no começo ou final de uma linha

# Âncoras (^ e $)

- Exemplos
  - Programas que começam com zip

```
$ grep -h '^zip' dirlist*.txt
zip
zipcloak
zipdetails
zipgrep
zipinfo
zipnote
zipsplit
```

  - Programas que terminam com zip

```
$ grep -h 'zip$' dirlist*.txt
funzip
gunzip
gzip
unzip
zip
```

  - Programa com nome exato de zip

```
$ grep -h '^zip$' dirlist*.txt
zip
```

# Escapes (\)

- Pode-se escapar qualquer caractere especial (mas não parênteses ou dígitos) colocando uma barra invertida antes do caractere

| Expressão Regular | Casamento | Exemplos |
|---|---|---|
| /end\./ | end + ponto | The **end.**, s**end.**, pret**end.**mail |
| /\\/ | Uma única barra invertida | **** |
| /*/ | Um asterisco (*) | ***.c, um asterisco (***)** |
| /\[5\]/ | [5] | it was five **[5]** |
| /and\/or/ | and/or | **and/or** |

- Exemplo

```
$ grep -h '\[' dirlist*.txt
[
```

# Agrupamento de Expressões Regulares

- Pode-se usar parênteses escapados, \( e \), para agrupar uma expressão regular – assim, a string que essa expressão regular casa pode ser recuperada posteriormente
  - A expressão regular não tenta casar o parêntese escapado

- Uma expressão regular entre parênteses escapados casa exatamente as mesmas strings que a expressão regular sem os parênteses casa
  - /a\(b*\)c/ casa o que /ab*c/ casa

Para quê serve isso?

- Ainda se pode aninhar agrupamentos, como na expressão /\([a–z]\([A–Z]*\)x\)/ que possui um agrupamento dentro de outro
  - Para a string **3 t dMNORx7 l u**, a expressão regular casa **dMNORx**, em que o primeiro agrupamento casa **dMNORx** e o segundo **MNOR**

# REGRA

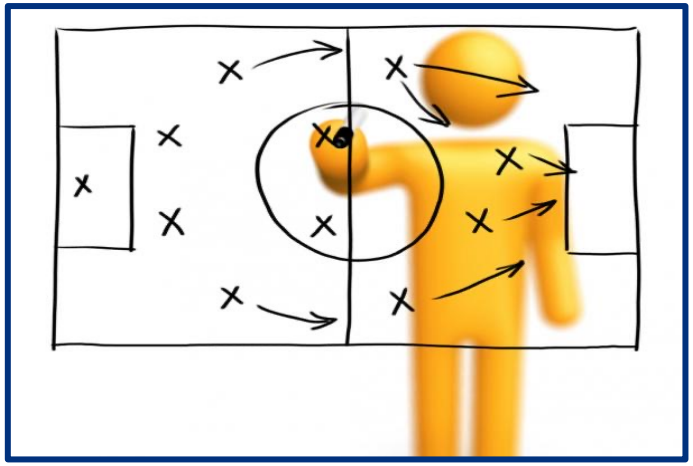

# Casamento da Maior Sequência Possível

- **Regra:** uma expressão regular SEMPRE casa a string mais longa possível, começando no mais próximo do começo da linha
- Exemplos
  - *This (rug) is not what it once was (a long time ago), is it?*
    - /Th.*is/

      ***This (rug) is not what it once was (a long time ago), is** it?*
    - /(.*)/

      *This **(rug) is not what it once was (a long time ago)**, is it?*
  - *singing songs, singing more and more*
    - */s.*ing/*

      ***singing songs, singing** more and more*
    - */s.*ing song/*

      ***singing song**s, singing more and more*

# SUBSTITUIÇÃO DE TEXTO

# Substituição de Texto

- Os editores de texto **`vim`** e **`sed`** usam expressões regulares como *strings* de busca em comandos de substituição

- Pode-se usar os caracteres especiais E comercial (**`&`**) ou dígitos escapados (**`\1`**, **`\2`**, ...) para representar as strings casadas na string de substituição correspondente

# E Comercial (&)

- Em uma string de substituição, um E comercial (&) recebe o valor da string que a string de pesquisa (expressão regular) casou

- Por exemplo, a expressão a seguir envolve o nome da shell entre dois sublinhados (__*SHELL*__)

```
$ echo $SHELL
/bin/bash
$ echo $SHELL | grep "[^/]*sh$"
/bin/bash
$ echo $SHELL | sed "s:[^/]*sh$:__&__:"
/bin/__bash__
```

# Dígito Escapado (*n*)

- Dentro da *string* de substituição, um dígito escapado (\n) representa a *string* que a expressão regular agrupada (aquela entre parênteses escapados), começando com a n-ésima \( casada

- Exemplo de uma lista de nomes no formato **last-name, first-name initials** e se deseja passar para o formato **first-name initials last-name**

```
$ cat megadeth.txt
Mustaine, David S.
Ellefson, David W.
Friedman, Martin A.
Menza, Nick
$ cat megadeth.txt | sed "s/\([^,]*\), \(.*\)/\2 \1/"
David S. Mustaine
David W. Ellefson
Martin A. Friedman
Nick Menza
```

# EXPRESSÕES REGULARES ESTENDIDAS

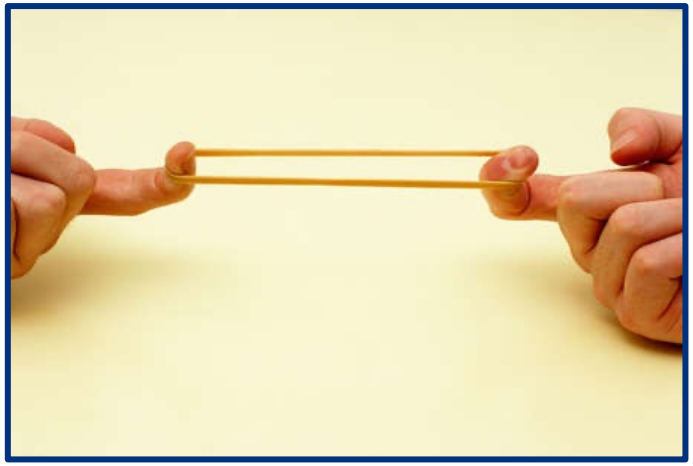

Shell Scripting

# Padronização POSIX

- A padronização POSIX separa a implementação de expressões regulares em dois tipos
  - Expressões regulares básicas (ERB)
  - Expressões regulares estendidas (ERE)

- Com ERB os metacaracteres `$ ^ . [ ] *` são reconhecidos, todos os outros são considerados literais; ERE adicionam os metacaracteres `( ) { } ? + |` com suas funções associadas
  - Interessante notar que os caracteres ( ) { } são tratados como metacaracteres no ERB quando escapados, enquanto em ERE qualquer caractere escapado é considerado literal

- Para usar expressões regulares estendidas pode-se usar a ferramenta `egrep` ou `grep` com a opção `-E`

# Expressão Regular Estendida

- Expressões regulares estendidas possuem duas funcionalidades
  - **Alternadores:** permitem casamento em um conjunto de expressões (ao invés de apenas uma)
  - **Quantificadores:** permitem especificar a quantidade de vezes que um elemento é casado
    - `?`: casa um elemento zero vezes ou uma vez
    - `*`: casa um elemento zero ou mais vezes
    - `+`: casa um elemento uma ou mais vezes
    - `{ }`: casa um elemento um número específico de vezes

# Alternadores

- Alternadores permitem casamento em um conjunto de expressões, casando uma delas

- Exemplo
  - Expressão regular AAA|BBB permite casar AAA ou BBB

```
$ echo "AAA" | grep -E "AAA|BBB"
AAA
$ echo "BBB" | grep -E "AAA|BBB"
BBB
$ echo "CCC" | grep -E "AAA|BBB"
$
```

  - Não está limitada a apenas duas expressões

```
$ echo "AAA" | grep -E "AAA|BBB|CCC"
AAA
```

# Alternadores

- Para combinar alternadores com outras expressões regulares, pode-se usar parênteses agrupando as expressões

- Exemplo
  - Todos os arquivos que começam com bz, gz ou zip

```
$ grep -Eh '^(bz|gz|zip)' dirlist*.txt
bzcat
bzcmp
bzdiff
bzip2
bzless
bzmore
gzcat
gzexe
gzip
zip
zipgrep
zipinfo
```

O que aconteceria se os parênteses fossem retirados?

# Quantificador ?: Zero ou Uma Vez

- O efeito do quantificador ? é tornar o "elemento precedente opcional"

- Exemplo: verificar se um número de telefone com DDD entre os parênteses, *(dd) dddd-dddd*, ou sem parênteses *dd dddd-dddd*

```
$ echo "(31) 1234-5678" | grep -E '^\(?[0-9][0-9]\)?
>  [0-9][0-9][0-9][0-9]-[0-9][0-9][0-9][0-9]$'
(31) 1234-5678
$ echo "31 1234-5678" | grep -E '^\(?[0-9][0-9]\)?
>  [0-9][0-9][0-9][0-9]-[0-9][0-9][0-9][0-9]$'
31 1234-5678
$ echo "AA 1234-5678" | grep -E '^\(?[0-9][0-9]\)?
>  [0-9][0-9][0-9][0-9]-[0-9][0-9][0-9][0-9]$'
$
```

# Quantificador *: Zero ou Mais Vezes

- Como o metacaractere ?, o * é usado para denotar um item opcional: mas, diferentemente de ?, o item pode ocorrer qualquer número de vezes (zero ou mais)

- Exemplo: verificar se é uma sentença, começa com letra maiúscula e possui qualquer sequência de letras maiúsculas e minúsculas e termina com ponto final

```
$ echo "This works." | grep -E '[[:upper:]][[:upper:][:lower:] ]*\.'
This works.
$ echo "This Works." | grep -E '[[:upper:]][[:upper:][:lower:] ]*\.'
This Works.
$ echo "this does not" | grep -E '[[:upper:]][[:upper:][:lower:] ]*\.'
$
```

# Quantificador +: Uma ou Mais Vezes

- O metacaractere + funciona de forma bastante similar ao *, mas necessita pelo menos uma instância do elemento para um casamento

- Exemplo: apenas linhas que possuem grupos de um ou mais caracteres alfabéticos separados por um único espaço

```
$ echo "This that" | grep -E '^([[:alpha:]]+ ?)+$'
This that
$ echo "a b c" | grep -E '^([[:alpha:]]+ ?)+$'
a b c
$ echo "a b 9" | grep -E '^([[:alpha:]]+ ?)+$'
$ echo "abc  d" | grep -E '^([[:alpha:]]+ ?)+$'
$
```

# Quantificador {}: Número Específico de Vezes

- Os metacaracteres { e } são usados para expressar o número mínimo e máximo de casamentos necessários

| Especificador | Descrição |
|---|---|
| {n} | Casa o elemento precedente se ocorrer exatamente **n** vezes |
| {n,m} | Casa o elemento precedente se ocorrer no mínimo **n** vezes, mas não mais que **m** vezes |
| {n,} | Casa o elemento precedente se ocorrer no mínimo **n** ou mais vezes |
| {,m} | Casa o elemento precedente se ocorrer não mais que **m** vezes |

- Exemplo: do formato do telefone

```
$ echo "(31) 1234-5678" | grep -E '^\(?[0-9]{2}\)? [0-9]{4}-[0-9]{4}$'
(31) 1234-5678
$ echo "31 1234-5678" | grep -E '^\(?[0-9]{2}\)? [0-9]{4}-[0-9]{4}$'
31 1234-5678
$ echo "031 1234-5678" | grep -E '^\(?[0-9]{2}\)? [0-9]{4}-[0-9]{4}$'
$
```

# ISSO É TUDO, PESSOAL!