

Tutorial do comando Awk



*Empresa Brasileira de Pesquisa Agropecuária
Embrapa Informática Agropecuária
Ministério da Agricultura, Pecuária e Abastecimento*

Documentos 103

Tutorial do comando *Awk*

Fábio Danilo Vieira

Embrapa Informática Agropecuária
Campinas, SP
2010

Embrapa Informática Agropecuária

Av. André Tosello, 209 - Barão Geraldo
Caixa Postal 6041 - 13083-886 - Campinas, SP
Fone: (19) 3211-5700 - Fax: (19) 3211-5754
www.cnptia.embrapa.br
sac@cnptia.embrapa.br

Comitê de Publicações

Presidente: *Silvia Maria Fonseca Silveira Massruhá*

Membros: *Poliana Fernanda Giachetto, Roberto Hiroshi Higa,
Stanley Robson de Medeiros Oliveira, Maria Goretti Gurgel Praxedes,
Adriana Farah Gonzalez, Neide Makiko Furukawa*

Membros suplentes: *Alexandre de Castro, Fernando Attique Máximo,
Paula Regina Kuser Falcão*

Supervisor editorial: *Neide Makiko Furukawa*

Revisor de texto: *Adriana Farah Gonzalez*

Normalização bibliográfica: *Maria Goretti Gurgel Praxedes*

Editoração eletrônica/Arte capa: *Suzilei Almeida Carneiro*

Fotos da capa: *Imagens livres disponíveis em <<http://www.stock.schng>>*

Secretária: *Carla Cristiane Osawa*

1ª edição on-line 2010

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte,
constitui violação dos direitos autorais (Lei no 9.610).

Dados Internacionais de Catalogação na Publicação (CIP) Embrapa Informática Agropecuária

Vieira, Fábio Danilo.

Tutorial do comando Awk / Fábio Danilo Vieira. - Campinas :
Embrapa Informática Agropecuária, 2010..

37 p. : il. - (Documentos / Embrapa Informática Agropecuária ;
ISSN 1677-9274, 103).

1. Comando awk . 2. Programação. 3. Scripts. 4. Shell. 5. Linux. I.
Título. II. Série.

005.15 CDD (21. ed.)

© Embrapa 2010

Autor

Fábio Danilo Vieira

Analista da Embrapa Informática Agropecuária
Av. André Tosello, 209, Barão Geraldo
Caixa Postal 6041 - 13083-970 - Campinas, SP
Telefone: (19) 3211-5798
e-mail: fabiodv@cnptia.embrapa.br

Apresentação

Mesmo que o Windows ainda seja, disparado, o sistema operacional mais utilizado e conhecido pelas pessoas no mundo todo, o Linux vem se difundindo cada vez mais em diversos nichos da população, sejam profissionais de informática ou não.

Uma das grandes vantagens do Linux sobre seu concorrente é a diversidade de comandos que seu terminal *shell* (interface de linha de comando) possui, o que se tornou uma característica forte deste sistema operacional.

O *awk* é um desses comandos que faz o terminal *shell* do Linux ser a marca forte desse sistema. É um comando tão importante e com tantas funcionalidades que muitos o confundem com uma linguagem de programação.

O presente trabalho procura fazer uma pequena introdução sobre as principais possibilidades de utilização do *awk*, desde a construção de simples linhas de comando até a programação de pequenos scripts para execução no shell do Linux.

Kleber Xavier Sampaio de Souza

Chefe Geral

Embrapa Informática Agropecuária

Sumário

O comando <i>awk</i>	9
Utilizando o <i>awk</i>	10
Listagem de dados	11
Os padrões usados pelo <i>awk</i>	13
Trabalhando com expressões relacionais	13
Trabalhando com expressões regulares.....	15
Utilizando BEGIN e END	17
As variáveis no <i>awk</i>	17
Operadores aritméticos do <i>awk</i>	21
Funções matemáticas	21
Trabalhando com cadeias de caracteres	23
O comando <i>if</i>	25
O comando <i>while</i>	27
O comando <i>for</i>	29

Um resumo dos comandos `break`, `continue`, `next`
e `exit`..... 30

Trabalhando com vetores 31

A saída com *print* 33

A saída formatada com *printf*..... 34

Recebendo parâmetros..... 35

Trabalhando com o *Shell* do Linux 36

Literatura recomendada..... 37

Tutorial do comando *Awk*

Fábio Danilo Vieira

O comando *awk*

Pela quantidade de recursos que possui e pela sua total integração ao *shell* (interface de linha de comando) do Unix e Linux, muitos consideram o *awk* como uma linguagem de programação. Comando ou linguagem, todos concordam que o *awk* é uma ferramenta excelente para resolver desde os problemas simples até os mais complexos que aparecem no dia-a-dia de usuários e administradores de sistemas operacionais Unix e Linux.

O *awk* possui esse nome em virtude dos sobrenomes dos três programadores que escreveram o comando: Alfred V. Aho, Peter J. Weinberg e Brian W. Kernighan. Eles queriam desenvolver um comando que englobasse as funções da família *grep* (*grep*, *egrep* e *fgrep*) e do *sed*, o que resultou no *awk*.

A função do *awk* é analisar um conjunto de linhas de entrada, uma por uma, procurando as que satisfaçam a determinados padrões ou condições especificados pelo usuário.

Veja a estrutura básica a seguir:

[padrão / condição]

[(ação)]

Exemplo:

```
awk '$1 == "Jose" { print $2, $3 }' arquivo1
```

O exemplo anterior ilustra bem uma típica instrução *awk*, ou seja, do tipo “**padrão-ação**”. A instrução mostrada imprime o segundo e o terceiro campos de cada linha do arquivo **arquivo1** quando o primeiro campo for igual a “Jose”. Em resumo, o comando *awk* irá executar a ação especificada (que pode ter diversos passos) para cada padrão ou condição que encontrar na linha que estiver lendo.

Utilizando o *awk*

Há duas formas de se executar o *awk*:

- A partir da linha de comando, como a seguir:

```
awk '<padrao-acao>' [arquivo_1] [arquivo_2] ...  
[arquivo_n]
```

Note que tanto o padrão quanto a ação vêm entre apóstrofes. Isso serve para inibir do *Shell* a interpretação de caracteres especiais, como o cifrão (\$), e também para permitir que o comando se prolongue por quantas linhas forem necessárias.

- A partir de um arquivo de comando, usando a opção *-f*, como a seguir:

```
awk -f <arquivo de programa> <lista de arquivos  
de entrada>
```

A leitura dos dados é feita linha por linha, que é por padrão uma sequência de caracteres terminada por um *new-line* (ASCII 10). E cada linha (ou registro) lida é dividida em campos, que, por padrão, são uma sequência de caracteres separados por <TAB> (ASCII 9) ou por espaços em branco.

Para continuarmos com nossas próximas explicações, vamos utilizar o arquivo **clientes**, que possui os seguintes registros:

```
$ cat clientes
```

```
Claudia Maria      Salvador           555-6666
Eduardo Silva      Campinas          222-3333
Juliano Mendes     Manaus            333-2222
Luiz Carlos        Curitiba          777-9999
Mario Sergio        Florianopolis     888-7777
Maria Julia        Salvador          666-8888
```

É importante notar que cada registro possui os campos: nome da pessoa, cidade e telefone, separados por <TAB>, e, no campo nome, o primeiro nome está separado do segundo por um espaço em branco. Nesse caso, então, temos 4 campos, pois por padrão, o *awk* interpreta **qualquer** espaço em branco como separador de campos. Entretanto, podemos definir o separador que queremos usar. Se definíssemos como **somente** <TAB>, por exemplo, os registros teriam somente 3 campos. Independente disso, o primeiro campo de um registro será chamado de \$1, o segundo de \$2 e assim por diante. O conjunto de todos os campos, ou seja, o registro inteiro será chamado de \$0.

Listagem de dados

Para se fazer uma listagem simples de um arquivo usando o *awk*, pode se usar o seguinte comando::

```
$ awk '{ print }' clientes
```

```
Claudia Maria      Salvador           555-6666
Eduardo Silva      Campinas          222-3333
Juliano Mendes     Manaus            333-2222
```

Luiz Carlos	Curitiba	777-9999
Mario Sergio	Florianópolis	888-7777
Maria Julia	Salvador	666-8888

Observe que a saída é idêntica a produzida pelo comando **cat** anterior. E se desejarmos imprimir apenas o primeiro e o terceiro campos, é só utilizar o \$1 e o \$3, como no exemplo a seguir:

```
$ awk '{ print $1, $3 }' clientes
```

```
Claudia Salvador  
Eduardo Campinas  
Juliano Manaus  
Luiz Curitiba  
Mario Florianópolis  
Maria Salvador
```

Note que apenas o primeiro nome, do campo nome, foi exibido, pois o *awk*, por padrão, interpreta tanto espaço em branco como <TAB> como separador de campos. Sendo assim, para o comando o campo cidade está na posição 3. Agora, se desejar que o separador seja o <TAB>, basta digitar o comando abaixo:

```
$ awk 'BEGIN{FS="\t"}{print $1, $3}' clientes
```

```
Claudia Maria 555-6666  
Eduardo Silva 222-3333  
Juliano Mendes 333-2222  
Luiz Carlos 777-9999  
Mario Sergio 888-7777  
Maria Julia 666-8888
```

Pode-se observar que agora o nome é listado por completo, e o campo telefone é considerado o terceiro campo (\$3). Mais adiante será explicado o que são as opções BEGIN e FS, mas, o que se pode adiantar é que a

opção FS (*Field Separator*) foi usada para mudar o separador de campos padrão para <TAB> (`\t`).

Os padrões usados pelo awk

O *awk* possui 3 formas de definir padrões, pelos quais se executam as ações:

- Padrões chamados de expressões relacionais, que servem para selecionar registros que atendam a determinadas condições de **comparação**;
- Padrões chamados de expressões regulares, que servem para selecionar registros que contenham determinadas **cadeias de caracteres**;
- Padrões especiais chamados BEGIN e END, que servem para determinar instruções a serem executadas **ANTES do processamento do primeiro registro e APÓS o último**, respectivamente (utilizado num exemplo anterior).

Trabalhando com expressões relacionais

Os padrões relacionais são usados para estabelecer comparações, sendo que os operadores utilizados são os definidos pela linguagem C (Tabela 1).

Tabela 1. Operadores relacionais utilizados pelo *awk*.

Operadores	Resultados
==	Igual a
>	Maior que
>=	Maior ou Igual
<	Menor que
<=	Menor ou Igual

Também podem ser utilizados os seguintes operadores lógicos (Tabela 2).

Tabela 2. Operadores lógicos utilizados pelo *awk*.

Operadores	Resultados
&&	E
	Ou
!	Não

No exemplo seguinte, vamos mostrar como é possível utilizar os operadores de comparação com cadeias de caracteres, listando os registros do arquivo **clientes** em que o primeiro campo (com o primeiro nome) inicie a partir da letra J:

```
$ awk '$1 > "J" { print }' clientes
Juliano Mendes   Manaus           333-2222
Luiz Carlos      Curitiba         777-9999
Mario Sergio     Florianópolis   888-7777
Maria Julia      Salvador         666-8888
```

É possível também montar expressões compostas, combinando operadores relacionais simples com os operadores lógicos || (ou), && (e) e ! (não).

Supondo que se esteja procurando o telefone de uma pessoa cujo segundo nome sabe-se que começa pela letra S ou M, pode-se usar o comando abaixo:

```
$ awk '$2 >= "M" || $2 >= "S" { print }' clientes
Claudia Maria   Salvador         555-6666
Eduardo Silva   Campinas         222-3333
Juliano Mendes  Manaus           333-2222
Mario Sergio    Florianópolis   888-7777
```

Trabalhando com expressões regulares

Para pesquisarmos um arquivo procurando por uma cadeia de caracteres usando expressões regulares, devemos colocar o padrão a ser encontrado entre um par de barras (/).

Por exemplo, se desejarmos listar os registros de clientes em que os nomes comecem pela letra “M”, usaríamos o seguinte comando:

```
$ awk '/M/ { print }' clientes
Claudia Maria    Salvador    555-6666
Juliano Mendes  Manaus     333-2222
Mario Sergio     Florianópolis 888-7777
Maria Julia      Salvador    666-8888
```

Podemos reparar que os dois primeiros registros não satisfazem o que queremos, mas a pesquisa, como foi feita, está correta. Se quisermos que apenas o nome, ou seja, o primeiro campo se inicie pela letra “M”, devemos usar \$1, como o exemplo a seguir:

```
$ awk '$1 ~ /M/ { print }' clientes
Mario Sergio     Florianópolis 888-7777
Maria Julia      Salvador    666-8888
```

No mundo das expressões regulares, os símbolos () [] \ ^ \$. * ? + | são metacaracteres com sentido especial. Os caracteres ^ e \$ servem, por exemplo, para pesquisar no início e no fim de uma cadeia de caracteres, respectivamente. Um grupo de caracteres entre colchetes ([]) servirá para pesquisar os registros que tenham um desses caracteres. Se quisermos, então, listar os registros em que o nome ou o segundo nome comecem por “C” ou “J”, fazemos o seguinte:

```
$ awk '$1 ~ /^[CJ]/ || $2 ~ /^[CJ]/ { print }' clientes
Claudia Maria    Salvador    555-6666
```

```

Juliano Mendes   Manaus           333-2222
Luiz Carlos      Curitiba        777-9999
Maria Julia      Salvador        666-8888

```

Podemos fazer uma pesquisa por um intervalo de valores, usando a estrutura:

```
padrão1, padrão2
```

como no exemplo a seguir, onde queremos os registros cujos nomes das pessoas contenham da letra “C” até a “J”:

```

$ awk '$1 ~ /C/ , /J/ { print }' clientes
Claudia Maria   Salvador        555-6666
Eduardo Silva   Campinas        222-3333
Juliano Mendes  Manaus          333-2222

```

Além dos metacaracteres citados anteriormente, o *awk* reconhece os seguintes caracteres (Tabela 3).

Tabela 3. Caracteres especiais utilizados pelo *awk*.

Sequência	Significado
<code>\n</code>	<i>Newline</i>
<code>\r</code>	<i>Carriage Return</i>
<code>\b</code>	<i>Backspace</i>
<code>\f</code>	<i>FormFeed</i>
<code>\t</code>	<TAB>
<code>\ddd</code>	Valor octal ddd

Vale lembrar que o caractere “\t” (do <TAB>) já foi utilizado num exemplo anterior.

Utilizando BEGIN e END

Quando precisamos fazer algum processamento antes que o *awk* faça a leitura do primeiro registro, usamos o padrão BEGIN (para fazer um cabeçalho, por exemplo). Se a necessidade é de fazer um processamento depois da leitura do último registro, devemos usar o padrão END (para gerar totais, por exemplo).

Por exemplo, para se colocar um cabeçalho e uma mensagem “Fim dos registros” no rodapé na leitura do arquivo clientes, deve-se utilizar o seguinte comando:

```
$ awk 'BEGIN { print "Nome\t\tCidade\t\tTelefone" } {
print } END { print "Fim dos registros" }' clientes
```

Nome	Cidade	Telefone
Claudia Maria	Salvador	555-6666
Eduardo Silva	Campinas	222-3333
Juliano Mendes	Manaus	333-2222
Luiz Carlos	Curitiba	777-9999
Mario Sergio	Florianópolis	888-7777
Maria Julia	Salvador	666-8888
Fim dos registros		

As variáveis no awk

O *awk* trabalha com dois tipos de variáveis:

- Variáveis definidas pelo próprio programador, ou seja, variáveis de trabalho que serão controladas pelo próprio programa.
- Variáveis Internas, que são variáveis pré-definidas e que são muito utilizadas pelo *awk*. Devem ser sempre usadas em letras maiúsculas, sem o cifrão (\$) precedendo-as, sendo que cada uma possui uma função.

Na Tabela 4, observa-se as variáveis internas do *awk*.

Tabela 4. Variáveis internas utilizadas pelo *awk*.

Variável	Significado
ARGG	Número de argumentos (parâmetros) recebidos pelo programa
ARGV	Vetor contendo os parâmetros passados para o programa
FILENAME	Nome do arquivo de entrada atual
FNR	Número do registro no arquivo atual
FS	Separador de campos. Seu padrão é branco e <TAB>
NR	Quantidade de registros do arquivo em processamento
OFMT	Formato de saída para números. Seu padrão é %.6g
OFS	Separador de campos na saída. Seu padrão é branco
ORS	Separador dos registros de saída. Seu padrão é newline
RS	Separador de registros de entrada. Seu padrão é newline

Alterando o exemplo dado anteriormente, iremos usar o padrão END para totalizar os registros processados, utilizando-se variável interna NR:

```
$ awk 'BEGIN { print "Nome\t\tCidade\t\tTelefone" }
{ print } END { print "Total de registros = " NR }'
clientes
```

```
Nome           Cidade           Telefone
Claudia Maria  Salvador         555-6666
Eduardo Silva  Campinas         222-3333
Juliano Mendes  Manaus           333-2222
Luiz Carlos    Curitiba         777-9999
Mario Sergio   Florianópolis    888-7777
Maria Julia    Salvador         666-8888
Total de registros = 6
```

Vamos ver um exemplo de como contar o número de registros que possuem um determinado padrão:

```
$ awk '$3 ~ /^S/ { print; soma=soma+1 } END {print
"Encontrados ", soma, " registros"}' clientes
Claudia Maria    Salvador        555-6666
Maria Julia      Salvador        666-8888
Encontrados 2 registros
```

No exemplo anterior, foi contado o número de registros em que o nome da cidade iniciasse por “S”, utilizando-se uma variável auxiliar chamada soma, a qual o *awk* inicializa automaticamente.

Para o próximo exemplo (e alguns outros também), estaremos utilizando o arquivo *carros*, o qual é composto do modelo do carro, da velocidade máxima, do tempo mínimo para ir de 0 a 100 km/h, do consumo mínimo e do preço médio. Vejamos o conteúdo do arquivo:

```
% cat carros
Corsa-3portas    150 15.20 12.20 16068.00
Corsa-4portas    182 11.10 10.00 16928.44
Corsa-Sedan      182 11.10 10.00 17376.49
Corsa-Wagon      183 12.20 12.71 20253.45
Pálio            188  9.50 10.90 19974.15
Pálio-Weekend    185 11.92 10.65 21200.44
Tipo             176 11.70 11.00 18310.70
Gol              175 12.40 11.60 16960.50
Parati           173 12.20 11.31 18809.22
```

Desse jeito, estão muito confusas as informações. Para melhorar esta visualização, foi construído um programa *awk*. É possível desenvolver um arquivo com extensão *awk* e construir os comandos *awk* dentro do mesmo. Para torná-lo executável, basta executar o comando “*chown a+x nome_do_arquivo.awk*”. Veja como ficou esse programa:

\$ cat listacar.awk

```
awk `
BEGIN { printf "%15s %10s %9s %7s %10s\n",
"Modelo", "Vel.Max.", "0 a 100", "Cons.", "Preco"; }
{printf "%15s %7s %11s %8s %11s\n", $1, $2, $3, $4,
$5;
VelM = VelM + $2 ; Pr = Pr + $5; }
END { printf "\n%7s\n%8s %5.2f\n%5s %10.2f\n",
"MEDIAS:", "Velocidade", VelM / NR, "Preco ", Pr / NR;
}' carros
```

O programa inicia-se com a criação de um cabeçalho dentro do padrão BEGIN, no qual se constrói a formatação desejada pelo comando printf (que veremos mais adiante). Os valores das velocidades e dos preços foram acumulados nas variáveis VelM e Pr, respectivamente e, logo depois, usando o padrão END, listadas as médias que foram calculadas, dividindo-se os totais das variáveis VelM e Pr pela quantidade de registros (NR).

Ao se executar o programa, a saída será a seguinte:

% ./listacar.awk

Modelo	Vel.Max.	0 a 100	Cons.	Preco
Corsa-3portas	150	15.20	12.20	16068.00
Corsa-4portas	182	11.10	10.00	16928.44
Corsa-Sedan	182	11.10	10.00	17376.49
Corsa-Wagon	183	12.20	12.71	20253.45
Palio	188	9.50	10.90	19974.15
Pálio-Weekend	185	11.92	10.65	21200.44
Tipo	176	11.70	11.00	18310.70
Gol	175	12.40	11.60	16960.50
Parati	173	12.20	11.31	18809.22

MEDIAS:

Velocidade 177.11

Preco 18431.27

Operadores aritméticos do *awk*

O processo de realização de contas em *awk* é muito similar ao da linguagem C. A seguir, na Tabela 5, é mostrada os operadores aritméticos do *awk*.

Tabela 5. Operadores aritméticos utilizados pelo *awk*.

Operadores	Resultados
+	Soma
-	Diferença
*	Multiplicação
/	Divisão
%	Resto de divisão
^ou **	Exponenciação
=	Igualdade

No *awk* também são aceitos operadores abreviados, como na linguagem C. Exemplos: ++, --, +=, -=, *=, /=, ^=.

Funções matemáticas

O *awk* possui diversas funções matemáticas internas para manipulação de dados numéricos, as quais estão na Tabela 6.

Tabela 6. Funções matemáticas utilizados pelo *awk*.

Função	Valor retornado
<code>sqrt (x)</code>	Raiz quadrada de x
<code>sin (x)</code>	Seno de x
<code>cos (x)</code>	Cosseno de x
<code>log (x)</code>	Logaritmo natural de x
<code>int (x)</code>	Parte inteira de x
<code>exp (x)</code>	Função exponencial de x
<code>rand (x)</code>	Gera um número randômico entre 0 e 1

Abaixo um exemplo com a função `sqrt` (raiz quadrada):

```
$ awk 'BEGIN { print "Raiz quadrada de 4 eh "sqrt(4) }'
```

Raiz quadrada de 4 eh 2

Veja outro exemplo, só que agora com a função `int` buscando a parte inteira da raiz quadrada de 10, que devolve um valor decimal:

```
$ awk 'BEGIN { print "Parte inteira da raiz quadrada de 10 eh "int(sqrt(10)) }'
```

Parte inteira da raiz quadrada de 10 eh 3

Trabalhando com cadeias de caracteres

Todas as cadeias de caracteres (ou *strings*) no *awk* são tratadas entre aspas (“ ”).

Essas cadeias de caracteres são formadas concatenando-se variáveis, constantes, campos, elementos de vetores (*arrays*), funções e outros programas.

Observe o exemplo a seguir:

```
$ awk '{ print NR ":" $0}' carros
1:Corsa-3portas 150 15.20 12.20 16068.00
2:Corsa-4portas 182 11.10 10.00 16928.44
3:Corsa-Sedan 182 11.10 10.00 17376.49
4:Corsa-Wagon 183 12.20 12.71 20253.45
5:Pálio 188 9.50 10.90 19974.15
6:Pálio-Weekend 185 11.92 10.65 21200.44
7:Tipo 176 11.70 11.00 18310.70
8:Gol 175 12.40 11.60 16960.50
9:Parati 173 12.20 11.31 18809.22
```

Como pode ser observado, cada registro do arquivo **carros** foi precedido pelo seu número sequencial no arquivo, seguido por dois-pontos (:), sem espaços em branco. Assim sendo, as três cadeias foram concatenadas e a cadeia resultante foi impressa, sem o uso de nenhum operador de concatenação, ou seja, para concatenar cadeias de caracteres basta justapor as mesmas.

O *awk* também possui várias funções internas para tratamento de cadeias de caracteres, que podem ser vistas na tabela seguinte, onde *c1* e *c2* são cadeias de caracteres, *exp* é uma expressão regular (que pode ser uma cadeia ou algo com */exp/*) e *p*, *n* são inteiros (Tabela 7).

Tabela 7. Funções manipulação de *strings* utilizados pelo *awk*.

Função	Valor retornado	Retorno
<code>index(c1, c2)</code>	Retorna a posição da cadeia c1 na cadeia c2	Zero se não presente
<code>length(c1)</code>	Retorna o tamanho da cadeia c1	--
<code>match(c1, exp)</code>	Retorna a posição em c1 onde exp ocorre	Zero se não presente
<code>split(c1, v [,c2])</code>	Divide c1 para o vetor v em cada c2 encontrado	Número de campos
<code>sprintf(fmt, lista)</code>	Retorna lista formatada de acordo com fmt	---
<code>sub(exp, c1 [,c2])</code>	A primeira exp encontrada na cadeia c2 é substituída por c1	Número de substituições
<code>gsub(exp, c1 [,c2])</code>	Toda exp encontrada na cadeia c2 é substituída por c1	Número de substituições
<code>substr(c1, p, n)</code>	Retorna a subcadeia que começa na posição p de c1 com n caracteres	--

A seguir, um exemplo usando `index`, que devolve a posição da primeira ocorrência de “E”:

```
$ awk 'BEGIN { print index("SISTEMA", "E") }'
```

5

Ao se utilizar o padrão `BEGIN`, não é necessário especificar nenhum nome de arquivo.

Vamos ver um exemplo usando a função `length`, que retorna o tamanho da string:

```
$ awk 'BEGIN { print length("SISTEMA") }'
```

7

Observe um exemplo usando a função `match`, que procura pela ocorrência de um padrão dentro de uma cadeia de caracteres:

```
$ awk 'BEGIN { print match("Joao Jose", /Jo+s/) }'
```

6

Foi retornado o valor 6, que corresponde ao nome “Jose”, pois foi procurado por uma sequência “Jo” seguida ou não de outro caractere “o” mais o caractere “s”.

A seguir, um exemplo usando a função `split`, que divide uma cadeia de caracteres num vetor de cadeias dependendo do separador usado em seu terceiro argumento (caso este seja passado, senão utiliza-se o valor da variável interna `FS`):

```
$ awk 'BEGIN { print split("ponto-e-virgula", v, "-")
}'
3
```

O retorno da função mostra que a cadeia foi dividida em 3 partes para o vetor `v`, que se listássemos, exibiria:

```
v[1] = "ponto"
v[2] = "e"
v[3] = "virgula"
```

O comando `if`

O comando `if` no `awk`, como na linguagem C, possui a seguinte sintaxe:

```
if (expressao)
{
    comando 1
    comando 2
    . . .
    comando n
}
else
{
    comando 1
    comando 2
    . . .
    comando n
}
```

}

Dentro de expressão pode ser incluídos operadores lógicos (`||`, `&&`, `!`), operadores relacionais (`<`, `<=`, `>`, `>=`, `==` e `!=`) e operadores de pesquisa em expressões regulares (`~` e `!~`).

Observe um exemplo do comando `if` utilizando o arquivo **carros** que, ao seu final, exibirá o carro mais veloz e o mais econômico:

```
$ cat velecon.awk
```

```
awk 'BEGIN { MinCons=99999 }
{
    if ( $2 > MaxVel )
    {
        CarVel=$1
        MaxVel=$2
    }
    if ( $4 < MinCons )
    {
        CarEcon=$1
        MinCons=$4
    }
}
END {
    print "O", CarVel, "eh o mais rápido, pois desenvolve ", \
        MaxVel, "km e\nO", CarEcon, "eh o mais econômico, pois faz", MinCons, "km/l\n"
}' carros
```

Executando este arquivo `awk`, a saída será:

```
$ ./velecon.awk
```

```
O Pálio eh o mais rápido, pois desenvolve 188 km e
O Corsa-4portas eh o mais econômico, pois faz 10.00
km/l
```

O comando `while`

A sintaxe do comando `while` é o seguinte:

```
while (expressao)
{
    comando 1
    comando 2
    . . .
    comando n
}
```

Os comandos dentro de `while` são executados até que o valor de expressão seja falso (0 - zero).

Vejamos um exemplo de `while` para listar cada campo do arquivo **carros** em uma linha:

```
$ cat camposcar.awk
```

```
awk '{
    i = 1
    while ( i <= NF )
    {
        print $i
        i ++
    }
}' carros
```

O script inicializará a variável `i` com 1 e o comando `while`, enquanto o valor de `i` for menor ou igual ao número de campos da linha atual, irá imprimir (`print`) cada campo em uma linha diferente, acrescentando 1 a `i` após a impressão (`print`). A saída gerada por esse script `awk` será a seguinte, com cada campo lido em uma linha diferente:

\$./camposcar.awk

Corsa-3portas

150

15.20

12.20

16068.00

Corsa-4portas

182

11.10

10.00

16928.44

Corsa-Sedan

182

11.10

10.00

17376.49

Corsa-Wagon

183

12.20

12.71

20253.45

Pálio

188

9.50

10.90

19974.15

Pálio-Weekend

185

11.92

10.65

21200.44

Tipo

```
176
11.70
11.00
18310.70
Gol
175
12.40
11.60
16960.50
Parati
173
12.20
11.31
18809.22
```

O comando `for`

A sintaxe do comando `for` é a seguinte:

```
for (expressao1; expressao2; expressao3)
{
    comando 1
    comando 2
    ...
    comando n
}
```

onde em `expressao1` se atribui, geralmente, o valor inicial de uma variável, que será incrementada pelo valor de `expressão3`, sendo que as instruções dentro das chaves (`{}`) serão executadas enquanto `expressao2` for verdadeira.

Veja como o exemplo anterior foi alterado para usar o comando `for` ao

invés do `while`:

```
$ cat camposcar2.awk
awk '{
    for ( i = 1; i <= NF; i++ )
    {
        print $i
    }
}' carros
```

Nesse exemplo, o comando `for` inicializou a variável `i` com 1, incrementando-a em 1 até que seu valor fosse menor ou igual ao número de campos do registro (NF). Ou seja, fez o mesmo que o comando `while` no exemplo anterior a este, sendo que a saída é exatamente igual também.

Um resumo dos comandos `break`, `continue`, `next` e `exit`

A seguir é dado um resumo dos comandos utilizados dentro dos comandos de laço explicados anteriormente, `while` e `for`:

- `break` – quando esse comando é encontrado, a execução do programa desvia para a primeira instrução após o `loop`;
- `continue` – assim que é encontrado, o fluxo do programa é desviado para a primeira instrução do `loop`;
- `next` – provoca o desvio do fluxo de comandos e voltará a pesquisar padrões a partir do comando da primeira dupla “padrão-ação”;
- `exit` – o comando `exit` faz o programa se comportar como se a leitura do arquivo tivesse acabado. Nada mais é lido e, se existir o padrão END, ele será executado.

Trabalhando com vetores

Os vetores e seus elementos são tratados da mesma forma que as variáveis, não necessitando também que sejam declarados, ou seja, passarão a existir assim que lhes for atribuído um valor.

A seguir, um exemplo de utilização de vetor para listar o arquivo **clientes** de trás para a frente:

```
$ cat tac.awk
awk `
{
    Registro [NR] = $0;
}
END {
    for ( i = NR; i >= 1; i-- )
    {
        print Registro[i]
    }
}' clientes
```

Nesse exemplo, foi guardado o conteúdo de cada linha do arquivo **clientes**, representada por \$0, dentro do vetor **Registro**. Usando o comando `for`, o programa faz um `loop` para listar cada linha do vetor, partindo da última linha (NR) até a primeira. Executando este `script`, o resultado é o seguinte:

```
$ ./tac.awk
Maria Julia      Salvador      666-8888
Mario Sergio    Florianópolis 888-7777
Luiz Carlos     Curitiba     777-9999
Juliano Mendes  Manaus      333-2222
Eduardo Silva   Campinas    222-3333
```

Claudia Maria

Salvador

555-6666

O *awk* permite também que indexemos os vetores com valores não numéricos. No exemplo a seguir, foi criado um vetor que armazena o campo velocidade do arquivo **carros**, sendo que o indexador é o campo modelo (não numérico):

```
$ cat indexauto.awk
```

```
awk `
{
    Velocidades [$1] = $2;
}
END {
    for ( Modelo in Velocidades )
    {
        print Modelo, "\t", Velocidades[Modelo]
    }
}' carros
```

Após a execução desse programa, a saída foi a seguinte:

```
$ ./indexauto.awk
```

```
Pálio-Weekend      185
Pálio               188
Tipo                176
Corsa-4portas      182
Gol                 175
Corsa-Wagon         183
Parati              173
Corsa-Sedan         182
Corsa-3portas      150
```

A saída com *print*

O comando `print` é a instrução mais usada para saída de dados no `awk`. Ele é usado para saída de dados simples, sem muita formatação.

Seu formato básico é:

```
print expressao_1, expressao_2, ... expressao_n
```

Ele imprime o valor de cada expressão separado pelo OFS colocando um ORS ao seu final

```
cat indexauto.awk
```

```
awk `
{
    Velocidades [$1] = $2
}
END {
    for ( Modelo in Velocidades )
    {
        print Modelo, "\t", Velocidades[Modelo] |
"sort"
    }
}` carros
```

o resultado será outro:

```
$ ./indexauto.awk
```

```
Corsa-3portas      150
Corsa-4portas      182
Corsa-Sedan        182
Corsa-Wagon        183
Gol                 175
Pálio               188
```

Pálio-Weekend	185
Parati	173
Tipo	176

A saída formatada com *printf*

O comando `printf` possui a seguinte sintaxe:

```
printf formato, expressao_1, expressao_2, ...
expressao_n
```

Onde `formato` é uma cadeia que contém tanto as informações a serem impressas quanto as definições dos formatos das cadeias resultantes de `expressao_1`, `expressao_2`, ... `expressao_n`. Os formatos sempre começam por um `%` e terminam por uma letra, conforme mostrada na Tabela 8.

Tabela 8. Opções do comando *printf*.

Letra	A expressão será impressa como:
c	Simples caractere
d	Número no sistema decimal
e	Notação científica exponencial
f	Número com ponto decimal
g	O menor entre os formatos <code>%e</code> e <code>%f</code> com supressão dos zeros não significativos
o	Número no sistema octal
s	Cadeia de caracteres
x	Número no sistema hexadecimal
%	Imprime um %

Na Tabela 9, pode-se ver exemplos de uso do *printf*:

Tabela 9. Exemplos de uso do *printf* no comando *awk*.

Entrada	Saída	
<code>printf "%d", 99/2</code>	49	
<code>printf "%e", 99/2</code>	4.950000e+01	Notação científica
<code>printf "%f", 99/2</code>	49.500000	
<code>printf "%6.2f", 99/2</code>	49.50	6 inteiros e 2 decimais sem zero à esquerda
<code>printf "%g", 99/2</code>	49.50	
<code>printf "%o", 9</code>	11	9 convertido para octal dá 11
<code>printf "%x", 20</code>	14	20 convertido para hexadecimal dá 14
<code>printf "[%s]", "Flamary"</code>	Flamary	Formato de edição de cadeias
<code>printf "[%15s]", "Flamary"</code>	Flamary	Ídem alinhando à direita, totalizando 15 posições
<code>printf "[%15s]", "Flamary"</code>	Flamary	15 posições alinhadas à esquerda
<code>printf "[%3smengo]", "Flamary"</code>	Flamengo	Só as 3 primeiras posições + cadeia mengo
<code>printf "[%10.2s]", "Eugenio"</code>	Eu	10 posições alinhadas à esquerda, pegando as 2 primeiras letras

Recebendo parâmetros

O *awk* permite também que passemos parâmetros para programas escritos com ele. Esses parâmetros serão recebidos por uma variável inteira e por um vetor. Essas variáveis são as seguintes:

- **ARGC** – Essa variável contém a quantidade de parâmetros recebidos;
- **ARGV** – Vetor que contém os valores recebidos. Seus elementos variam desde `ARGV[0]`, que contém o nome da rotina, até `ARGV[ARGC – 1]`.

Vejamos um exemplo com o uso dessas variáveis:

```
$ cat param.awk
awk `
BEGIN {
    for (i = 0; i < ARGC; i++)
```

```

    {
        print ARGV[i], "\n"
    }
}' $*
```

Trabalhando com o *Shell* do Linux

Em todos os exemplos mostrados até aqui, com exceção do anterior, o *awk* não interagiu com o *shell* (interface de linha de comando) do Linux. Nesses exemplos, para evitar que o *shell* interpretasse algum caractere das instruções do *awk* (já que alguns deles são significativos para o *shell*), sempre eram colocados apóstrofes em volta dessas instruções.

Vamos ver um exemplo em que isso pode ser percebido, pois o \$1 será interpretado pelo *shell*, e não pelo *awk*:

```

$ cat procura.awk
awk '/'$1'/' clientes
```

Observe que o que estão entre apóstrofes são os caractere barra (/), e não \$1. Portanto, \$1 está sob interpretação do *shell*, e não do *awk*. Se fosse interpretado pelo *awk*, \$1 seria o primeiro campo do arquivo, como sabemos, mas para o *shell*, \$1 será interpretado como sendo o primeiro parâmetro passado para o programa *procura.awk*. Veja um exemplo da execução dele:

```

$ ./procura.awk Mario
Mario Sergio      Florianópolis      888-7777
```

O programa procurou pelo parâmetro passado “Mario” dentro do arquivo **clientes**, encontrando apenas um registro.

Em resumo, a possibilidade de programas e linhas de comandos que se pode desenvolver que lidam com arquivos textos utilizando *awk* é infinita, bastando apenas o programador ter uma necessidade em que este co-

mando possa atuar. Obviamente, haverá casos em que o *awk* não será a solução ideal, mas saber desenvolver com esta ferramenta poderá ajudar bastante enquanto essa solução ideal não seja encontrada.

Literatura recomendada

AURELIO.NET [Site do autor]. Disponível em: <<http://aurelio.net/shell/>>. Acesso em: 13 dez. 2010.

NEVES, J. C. **Programação Shell Linux**. Rio de Janeiro: Brasport, 2005. p. 261-295.

Embrapa

Informática Agropecuária

**Ministério da
Agricultura, Pecuária
e Abastecimento**



CGPE 9059