

EXPRESSÕES REGULARES

(ER, Ereg ou RegEx)

- ♦ **Uma expressão regular é essencialmente um padrão. É com base nesse padrão que a expressão em questão será avaliada.**
- ♦ **Uma expressão regular, na Informática, define um padrão a ser usado para procurar ou substituir palavras ou grupos de palavras. É um meio preciso de se fazer buscas de determinadas porções de texto.**
- ♦ **São um método rápido e simples de manipulação e combinação avançada de strings.**

Caracter ^

Este é o primeiro operador que vamos aprender. O ^ indica que a expressão deve iniciar com a string dada.

^flu

Esta sintaxe irá definir que a string dada deverá começar com 'flu'. No caso, "fluzão é a máquina" seria uma string concordante. Porém, se você tentar "Após a goleada o flu terá descanso", não obterá sucesso.

Caracter \$

Como existe o ^ para definir o começo, temos \$ para definir o final. Com \$ defini-se a string que deverá cocordar com o final.

flu\$

Esta sintaxe irá definir que a string dada deverá terminar com 'flu'. Tentando validar a string "E o campeão é o flu" obteremos sucesso, o que não acontecerá com a string "O flu foi o campeão".

Outros Caracteres

\backslash - É utilizado para não interferir na função utilizada.

Ex: Se você por um "(" para comparar, ela irá interferir na função

Solução: colocar um $\backslash($, assim também com as aspas $\backslash"$.

* - Identifica qualquer seqüência de caracteres.

? - Identifica um caractere qualquer.

$\{x\}$ - Traz "x" caracteres de uma seqüência (x deve ser número natural).

$\{x, y\}$ - Traz entre "x" e "y" caracteres de uma seqüência (x e y devem ser números naturais).

. - Identifica qualquer caractere.

$x|y$ - O "|" identifica uma condição, no caso se não for o caractere "x" irá ser o "y".

Outros Caracteres

\d - Marca uma seqüência de caracteres números.

\D - Marca uma seqüência de não-números.

\w - Marca uma seqüência de caracteres alfabéticos.

\W - Marca uma seqüência de caracteres não-alfabéticos.

\s - Identifica caracteres "em branco" tipo o barra de espaço.

Caracteres em Branco e Caracteres de Escape

Assim como na sintaxe PHP, em expressões regulares também tem que utilizar de caracteres de escape, como:

`\n` - Nova linha

`\f` - Avanço de página

`\r` - Retorno de carro

`\.` - Qualquer caractere

`\\` - Uma barra invertida literal

`\-` - Um hífen literal

Classes de Caracteres

Classes de caracteres são uma espécie de grupo que contêm todas as ocorrências que deverão (ou não deverão) constar em uma expressão

Ex: Para permitir apenas letras vogais, usa-se:
[AaEeIiOoUu]

Então com este código teríamos um padrão que só permitirá que apenas vogais estejam na string dada.

Intervalo de caracteres

[a-z] - Qualquer letra minúscula

[A-Z] - Qualquer letra maiúscula

[a-zA-Z] - Qualquer letra maiúscula ou minúscula

[0-9] - Qualquer número

[0-9\.\-] - Qualquer número, ponto ou sinal de subtração

Isto serve apenas para combinação de UM caractere.

Classes de Caracteres

`^[a-z][0-9]$`

A expressão de apenas dois caracteres em que o primeiro tem necessariamente que ser uma letra minúscula e o segundo ser um número.

ATENÇÃO: operador `^`! fora de uma classe de caracteres, ele serve para demonstrar o que deve haver no início, porém dentro, ele serve para mostrar o que não deve ocorrer.

`^[^0-9][0-9]$`

A expressão deve começar com um caractere que não seja um número e seja imediatamente seguido por um caractere que será um número.

Classes de Caracteres Pré-definidas

As classes de caracteres pré-definidas que já vêm junto com o interpretador de ER que você estiver utilizando (apresentando apenas o método POSIX).

`[[:alpha:]]` // Qualquer letra (alfabético)

`[[:digit:]]` // Qualquer número (dígito)

`[[:alnum:]]` // Qualquer letra ou número (alfanumérico)

`[[:space:]]` // Qualquer caractere de espaço

`[[:upper:]]` // Qualquer letra maiúscula

`[[:lower:]]` // Qualquer letra minúscula

`[[:punct:]]` // Qualquer caractere de pontuação

`[[:xdigit:]]` // Qualquer dígito hexadecimal (Equivalente a:
`[0-9a-fA-F]`)

Ocorrências Múltiplas

Agora vamos pra parte em que realmente começa a fazer sentido usar-se expressões regulares.

`^[[:alpha:]]{3}$` // Qualquer palavra de três letras

`^a{4}$` // Só fecha com a expressão 'aaaa'

`^a{2,4}$` // Fecha com 'aa', 'aaa' e 'aaaa'

`^a{2,}$` // Fecha com 'aa', 'aaa', 'aaaa', 'aaaaa', ...

Outras formas de representar a repetição de caracteres

? - Uma ocorrência ou nenhuma (Equivale a $\{0,1\}$)

* - Nenhuma ocorrência, uma ocorrência, duas ocorrências, ...
(Equivale a $\{0,\}$)

+ - Uma ou mais ocorrências (Equivale a $\{1,\}$)

Alternação e Parênteses

Lógico OR (|)

f|c é equivalente a [fc]

Para caracteres simples é com certeza mais conveniente utilizar as classes. A alternção é basicamente útil para utilizar alternância de palavras.

Arroz|Feijão|Angu

Esta expressão só irá retornar verdadeiro se a string dada for "Arroz" OU "Feijão" OU "Angu".

Alternação e Parênteses

Parênteses ()

ex: Flu+

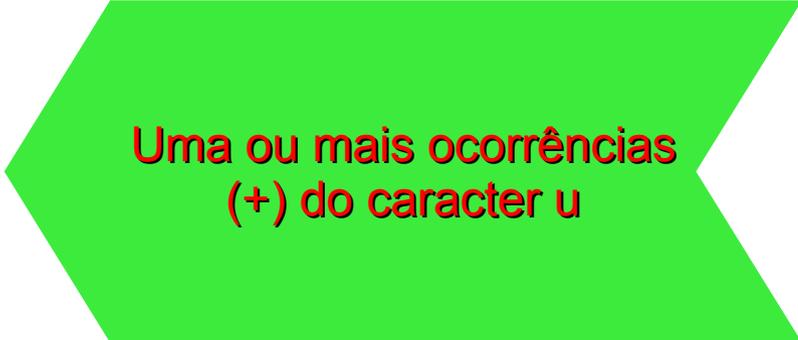
Somente fecharia com:

Flu

Fluu

Fluuu

Fluuuu...



Uma ou mais ocorrências
(+) do caracter u

Porém com os parênteses, temos um jeito mais interessante de interar com palavras repetidas.

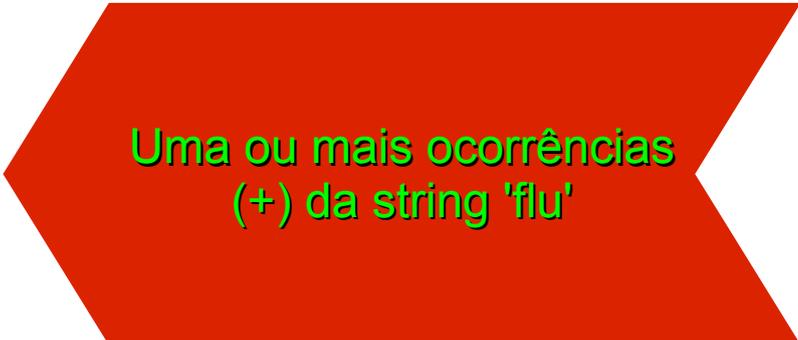
(flu)+

Irá fechar com:

flu

fluflu

flufluflu



Uma ou mais ocorrências
(+) da string 'flu'

Alternação e Parênteses

`(ci|experi|decad)encia`

Irá retornar verdadeiro com:

ciencia

experiencia

decadencia

`Arroz|Feijão$` - Retorna verdadeiro com 'Arroz' em qualquer parte da string ou com 'Feijão' no final

`(Arroz|Feijão)$` - Retorna verdadeiro tanto com "Arroz" quanto "Feijão", porém, no final da string

`([ab])([xy])` - Retorna verdadeiro com 'ax', 'ay', 'bx' e 'by' em qualquer parte da string

Aplicando Expressões Regulares em PHP

EREG

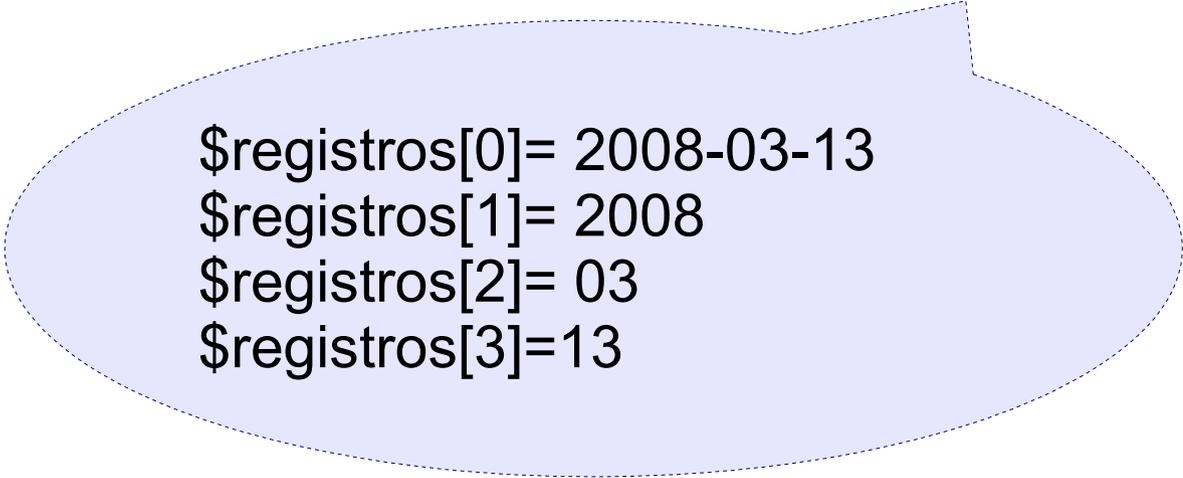
`bool ereg (string expressao, string variavel [, array registros])`

Verifica se a variavel casa com a expressão regular definida em expressão em um modo sensível a distinção de caracteres (case sensitive).

Se existirem parenteses de substrings na expressão e for passado o terceiro parâmetro (registros) para a função, a execução guardará os elementos resultantes na matriz registros.

`$registros[1]` irá conter a substring indicada pelo primeiro parenteses da esquerda;
`$registros[2]` contém a segunda substring, e assim por diante.
`$registros[0]` conterá uma cópia completa da variavel casada.

Ex: `$data = "2008-03-13";`
`ereg ("([0-9]{4})-([0-9]{1,2})-([0-9]{1,2})", $data, $registros)`



```
$registros[0]= 2008-03-13  
$registros[1]= 2008  
$registros[2]= 03  
$registros[3]=13
```

EREG

Nota: Nas versões superiores ao PHP 4.1.0 (inclusive) se você colocar exatamente dez elementos em \$registros, ou até mesmo mais elementos, a expressão será executada.

A quantidade não causará efeitos na função ereg() que tem habilidade de suportar muitas substrings. Se a expressão não casar, \$registros não será alterada por ereg().

EREGI

bool eregi (string expressao, string variavel [, array registros])

Essa função é idêntica a função ereg() com exceção de não fazer distinções alfabéticas entre caracteres (case insensitive) na hora de casar resultados.

```
Ex: $variavel = "Zorro !";  
    if (eregi("z", $variavel))  
    {  
    echo "A '$variavel' contém a letra 'z' ou 'Z'!";  
    }
```

EREG_REPLACE

string `ereg_replace` (string `expressao`, string `substituicao`, string `variavel`)

Essa função busca em `variavel` resultados para a expressão, substituindo se casar pelo texto em substituição.

A `variavel` modificada será retornada (poderá ocorrer da string original ser retornada caso não aconteça nenhuma substituição).

Por exemplo, o pedaço de código seguinte imprimirá "Esse foi um teste"

```
Ex: $string = "Esse e um teste<br>";  
    echo ereg_replace (" e", " foi", $string);
```

EREG_REPLACE

Atenção: Usar uma variável integer no parâmetro substituição, pois o resultado pode não ser exatamente o esperado.

```
Ex: $num = 5;  
    $string = "Essa frase tem cinco palavras<br>";  
    $string = ereg_replace('cinco', $num, $string);  
    echo $string; // Resultado: 'Essa frase tem  palavras.'
```

Isso acontece porque a função `ereg_replace()` interpreta o valor ordinal do número.

```
Ex:$num = '5';  
    $string = "Essa frase tem cinco palavras <br>";  
    $string = ereg_replace('cinco', $num, $string);  
    echo $string; // Resultado: 'Essa frase tem 5 palavras.'
```

EREG_REPLACE

Ex: Substitui URLs por links

```
$text = ereg_replace("[[:alpha:]]+://[^\<>[:space:]]+[[:alnum:]]/",  
"<a href=\"\0\">\0</a>", $text);
```

EREG_REPLACE

Ex: Substitui URLs por links

```
$text = ereg_replace("[[:alpha:]]+://[^\<>[:space:]]+[[:alnum:]]/",  
"<a href=\"\0\">\0</a>", $text);
```

EREGI_REPLACE

string eregi_replace (string expressão, string substituição, string variavel)

Essa função é idêntica a ereg_replace() com exceção de não fazer distinções alfabéticas entre caracteres (case insensitive) na hora de casar resultados.

STR_REPLACE

mixed str_replace (mixed pesquisa, mixed substitui, mixed assunto [, int &count])

Esta função retorna uma string ou um array com todas as ocorrências de pesquisa em assunto substituídas com a o valor dado para substitui.

```
Ex: $string = " o @ é usado em endereços de e-mail como  
rafa@processware.com.br";  
    echo str_replace ("@", " ARROBA ", $string);
```

Substituindo valores na string usando Arrays

```
Ex: $frase = "você torce para o Santos de Pelé e Robinho." ;  
    $antigo = array("Santos", "Pelé", "Robinho");  
    $novo = array("Fluzão", "Washington", "Dodo");  
    $novafrase = str_replace($antigo, $novo, $frase);  
    echo $novafrase;
```

STR_REPLACE

ATENÇÃO: Uso do parâmetro count está disponível no PHP 5.0.0

```
Ex: $str = str_replace("r", "", "O rato roubou o remédio", $count);  
    echo $count;
```

EXPRESSÕES REGULARES

“Mais comuns...”

Validação de E-Mail

```
$string = "email@email.com";  
$pattern = "/(\w{3,15})@{1}(\w{2,15})\.com(\.)?(\w{2})?/";  
if(preg_match($pattern,$string,$veto))  
{  
echo $veto[0];  
}  
else  
{  
echo "E-mail inválido";  
}
```

PREG_MATCH

preg_match verifica se uma ER casa (retorna true) ou não casa (retorna false)

Validação de E-Mail

```
$email = "email@email.com";  
$express = "/(\w{3,15})@{1}(\w{2,15})\.com(\.)?(\w{2})?/";  
if(preg_match($express,$email,$saida))  
{  
echo $saida[0];  
}  
else  
{  
echo "E-mail inválido";  
}
```

Entendendo a expressão:

/(\w{3,15}) - Verifica se existe um conjunto de letras entre 3 e 15 caracteres.

@{1} - Avalia se existe um arroba.

(\w{2,15}) - Verifica se existe um conjunto entre 2 e 15 letras.

\.com - Avalia se existe um .com

(\.)? - Condição que indica se existe um . após o com

(\w{2})?/ - Avalia se existe 2 letras.

Números Telefônicos

Considerando o formato: xxx – xxxx-xxxx (com DDD)

Máscara: (2 ou 3 numeros) – (4 a 7 numeros) – (4 numeros)

```
$string = "021-2567-4324";  
if (preg_match('/^([0-9]{2,3})([-]?[0-9]{4,7})([- ]?[0-9]{4,4})?$/', $string)) {  
    echo "telefone valido.";  
}  
else  
{  
    echo "telefone invalido.";  
}
```

Considerando o formato: xxxx-xxxx (sem DDD)

Máscara:(4 a 7 numeros) – (4 numeros)

```
$string = "2567-4324";  
if (preg_match('/^[0-9]{4,7}([- ]?[0-9]{4,4})?$/', $string)) {  
    echo "telefone 2 valido.";  
}  
else  
{  
    echo "telefone 2 invalido.";  
}
```

Validando uma URL

```
$url = "xxxxxxxxxxxhttp://www.yart.com.brmnopqrstuvxz";  
$validador = "/([http:\V]{7})?w{3}\.{1}?[a-z]{3,15}\.[com]{3}(\.?)?(\w{2})?/";  
preg_match($validador,$url,$vet);  
echo $vet[0];
```

Entendendo a expressão:

([http:\V]{7})? – caso exista um http://

w{3}\.{1}? – caso exista 3 w (www) e após um ponto final

[a-z]{3,15} – depois exista uma seqüência de a à z entre 3 e 15 letras

\.[com]{3} – caso exista um .com

(\.)?(\w{2})? - E depois de tudo avalia caso exista ou não um . mais dois caracteres (.br ou .uk)

Validando um endereço IP

```
$ip = "120.0.0.100";  
$teste = "/^(25[0-5]|2[0-4][0-9]|[01]?[0-9][0-9]?)\.(25[0-5]|2[0-4][0-9]|[01]?[0-9][0-9]?)\.(25[0-5]|2[0-4][0-9]|[01]?[0-9][0-9]?)\.(25[0-5]|2[0-4][0-9]|[01]?[0-9][0-9]?)$/" ;  
if(preg_match($teste,$ip,$res))  
{  
echo "valida o endereco  ". $res[0];  
}  
else  
{  
echo "nao valida o endereco  ". $ip;  
}
```

Entendendo a expressão:

/^(25[0-5] - Inicia com 25x, onde x = {0...5}

| - ou

2[0-4][0-9] - Inicia com 2 xy, onde x = {0...4} e y = {0...9}

| - ou

[01]?[0-9][0-9]? - Inicia com 0 ou 1, seguido de {0...9} e {0...9}

o mesmo vale para o restante da expressão

Validando um endereço IP

Observe que pode-se fazer o mesmo com funções, porém expressões regulares são mais práticas

```
function ipValida($ip)
{
    if(!eregi("^([0-9]{1,3}\.){3}[0-9]{1,3}$", $ip))
        return false;

    $tmp = explode(".", $ip);
    foreach($tmp as $sub){
        $sub = $sub * 1;
        if($sub<0 || $sub>256) return false;
    }
    return true;
}
```



Todas as expressões regulares apresentadas neste resumo possuem erros de lógica de validação.

Ex: na expressão de validação de e-mail, só testamos se existe o .com após o domínio, assim .comxxxx retorna como válido e não é

Um outro erro é de que existem domínios como .eti, .inf, .br ,e muitos outros que são válidos e a expressão retorna como falso.

Na validação do nome, não é validado números e (ex: email123@email.com) isso é possível

Existem erros de lógica em todas as expressões !

O objetivo deste documento é apresentar a sintaxe básica de RegEx.

Arrume os erros das expressões apresentadas, com um exercícios prático sobre o assunto.

