

Expressões gananciosas

Transcrição

Vamos continuar com os grupos, mas ver um novo exemplo. Praticar é tudo com Regex! O nosso alvo agora é uma tag HTML, escolhamos um cabeçalho (`<h1>`) da nossa página e a tarefa é extrair o conteúdo. O alvo é:

```
<h1 class="text-left">Expressões regulares</h1>
```

Mãos à obra para definir a regex!

Ganancioso ou preguiçoso?

Nossa regex começa com os valores literais `<h1` seguido por qualquer caractere (`.`), uma ou mais vezes. Assim garantimos que todos os atributos da tag serão encontrados. No final colocamos o fechamento da tag (`>`):

```
<h1.+.>
```

Ao testar percebemos que a tag inteira foi selecionada e não só a primeira parte:

Expressões regulares

Target string (alvo)

```
<h1 class="text-left">Expressões regulares</h1>
```

Pattern (expressão regular)

```
<h1.+.>
```

Executar Regex

☐ Mostra índice ☐ Mostra grupos

1 Matches (resultados)

```
<h1 class="text-left">Expressões regulares</h1>
```

Highlight

```
<h1 class="text-left">Expressões regulares</h1>
```

Como assim? Nossa regex é gananciosa por padrão e selecionou todos os caracteres até o último `>`. O *meta-char*, que na verdade é ganancioso, é o `+`, igualmente `*` e `{}` são também assim, e sempre selecionam o máximo de caracteres possíveis, se não for configurado diferente. Ou seja, podemos dizer que não queremos "ganância" e sim preguiçoso ou hesitante. Isso se faz, novamente pelo caractere `?`:

```
<h1.+?>
```

Isso faz que a regex só seleciona até o primeiro `>`:

`<h1 class="text-left">`Expressões regulares`</h1>`

Para entender melhor, um bom teste pode ser testar a regex: `<h1.{1,10}` gananciosa, e depois a preguiçosa: `<h1.{1,10}? .` A primeira seleciona 10 caracteres depois do `<h1`, a segunda apenas 1 caractere.

Continuando com a elaboração da regex, vamos definir o conteúdo dentro do parágrafo, aproveitando as classes de caracteres já vistas:

```
<h1.+?>([\w\sõãí. ]+)
```

Dentro dos colchetes, podemos declarar mais caracteres do alfabeto português, mas para o nosso texto isso já é suficiente. Por fim falta selecionar o fechamento da tag:

```
<h1.+?>([\w\sõãí. ]+)</h1>
```

Repare que já usamos um grupo para receber o conteúdo do parágrafo de volta.