Linguagem de Consulta XPath

Caminhos, predicados, ancestrais e funções

Prof. Walmes Zeviani

walmes@ufpr.br

Laboratório de Estatística e Geoinformação
Departamento de Estatística
Universidade Federal do Paraná

Introdução

Motivação

- **XPath** é uma linguagem de consulta para XML.
- Ela é baseada em notação de caminhos e é bastante flexível.
- Com XPath pode-se:
  - Utilizar regras lógicas em atributos e conteúdo.
  - Descrever caminhos baseados em relação vertical e horizontal.
  - Aplicar funções numéricas e de texto.
- Existem outras formas de apontar para extração mas geralmente são subótimas comparadas ao XPath.

Introdução

Objetivos

- Introduzir o básico da sintaxe XPath para consultas.
- Apresentar uso dos predicado e genealogia em consultas XPath.
- Ilustrar o uso de predicados, operadores e funções.

XPath

Características

- É uma **linguagem de consulta** para endereçamento e extração de informação em documentos XML/HTML.
- É um padrão do *World Wide Web Consortium* (W3C).
- Só funciona com a representação DOM do documento e descreve caminhos pelos nós e ramos da árvore.
- Uma instrução XPath retorna o conteúdo que bate com o caminho descrito.
- Em alguns aspectos, se assemelha a Expressões Regulares.

Documentação do XPath no W3C

Documentação

1. XPath está na versão 3.1.
2. Documentação para cada versão: https://www.w3.org/TR/xpath/all/.
3. De acordo com o código fonte, a `libxml2` usa o XPath 1.0.

Tutoriais

3. https://www.w3schools.com/xml/xpath_intro.asp.
4. https://docs.marklogic.com/guide/xquery/xpath;
5. https://www.tutorialspoint.com/xpath/.
6. http://www.utools.nl/downloads/XPathReference.pdf.

Cartões de referência e testadores online

Cartões de referência

1. http://ricostacruz.com/cheatsheets/xpath.html.
2. http://xpath.alephzarro.com/content/cheatsheet.html.
3. http://www.mulberrytech.com/quickref/XSLT_1quickref-v2.pdf.

Testadores online de XPath

1. http://xpather.com/.
2. http://codebeautify.org/Xpath-Tester.
3. http://www.webtoolkitonline.com/xml-xpath-tester.html.
4. http://www.freeformatter.com/xpath-tester.html.

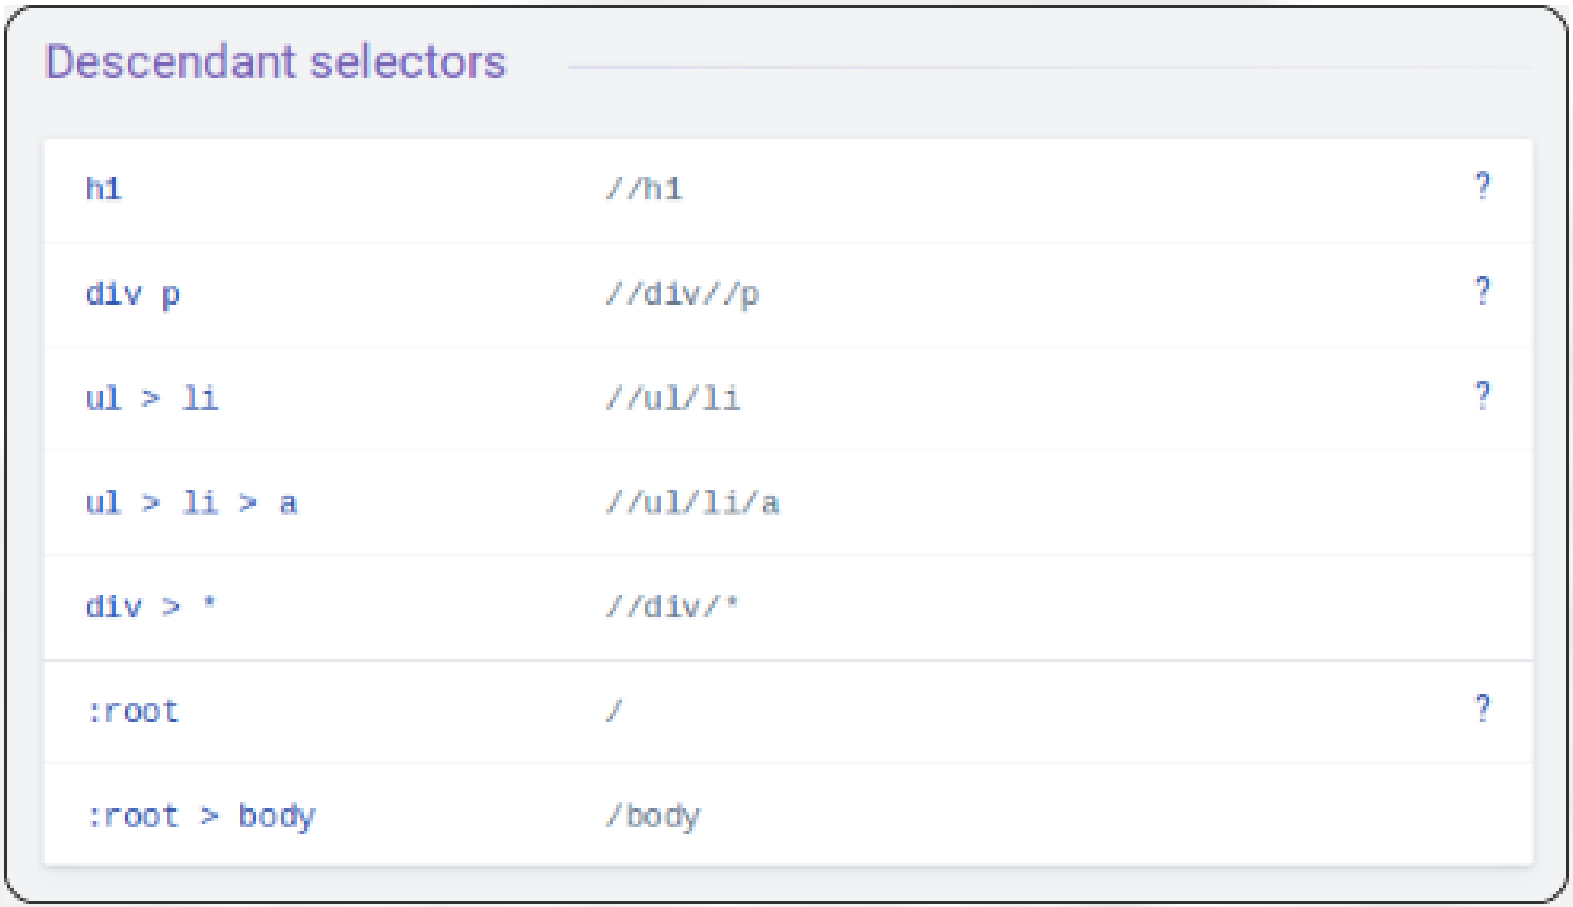

Figura 1. Seleção de descentes. Fonte: https://devhints.io/xpath.

Prefixes

Prefix	Example	What
`//`	`//hr[@class='edge']`	Anywhere
`./`	`./a`	Relative
`/`	`/html/body/div`	Root

Begin your expression with any of these.

Figura 2. Significado dos prefixos. Fonte: https://devhints.io/xpath.

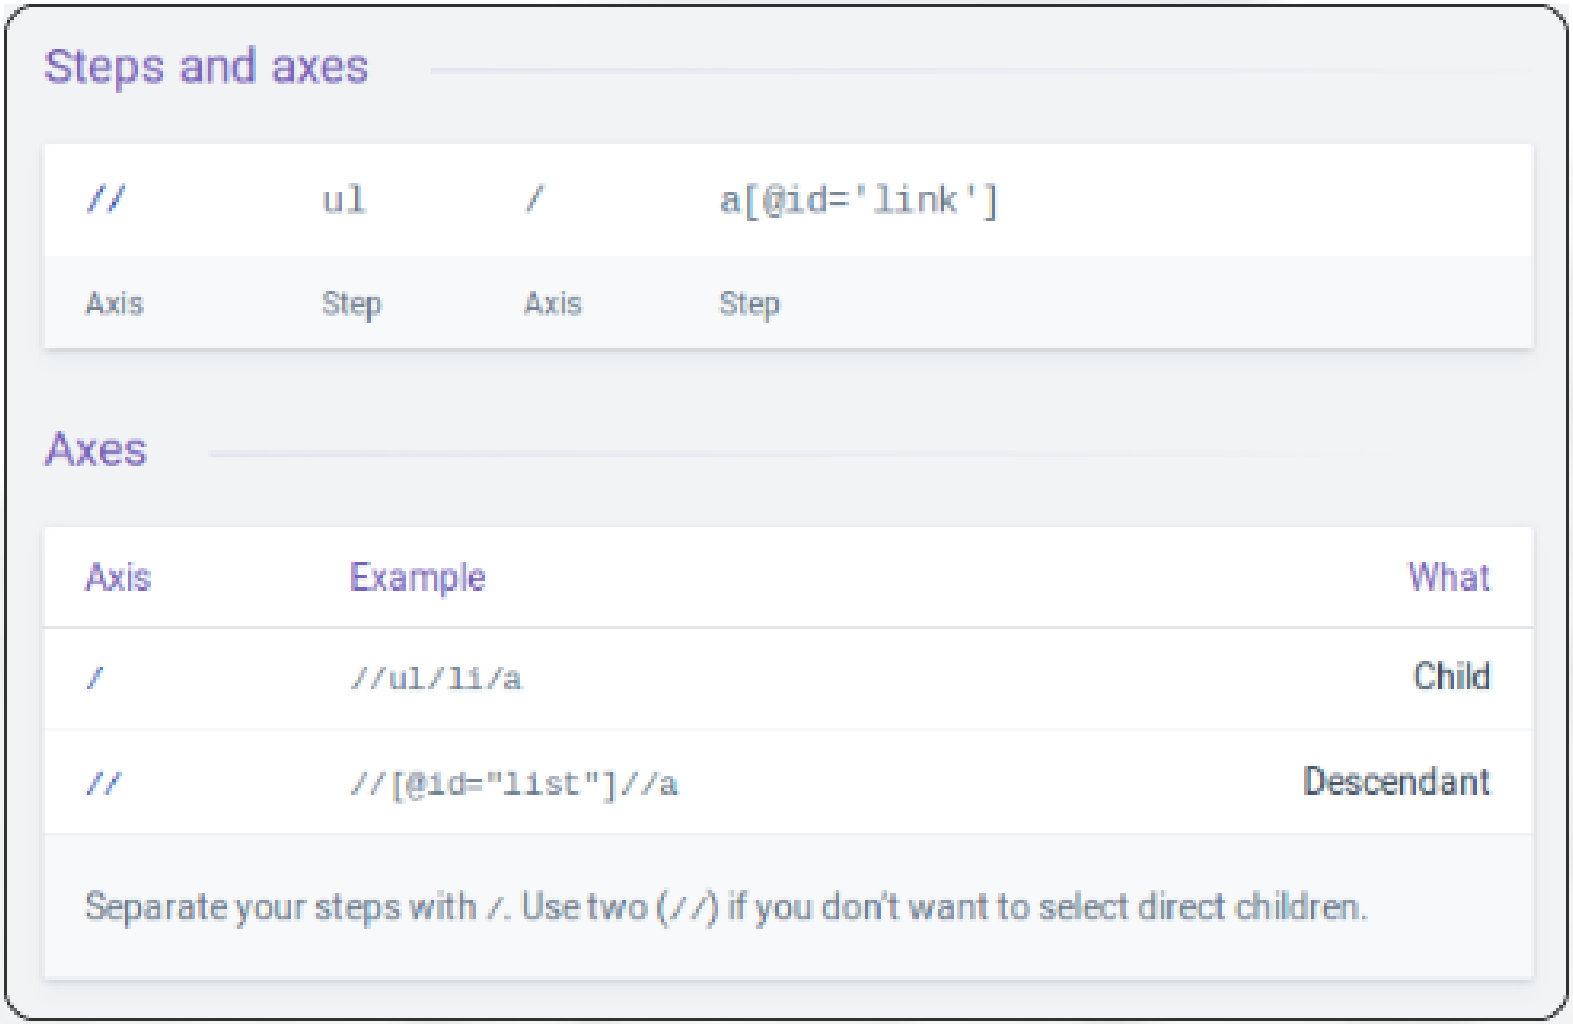

Figura 3. Combinação de seleção e prefixos. Fonte: https://devhints.io/xpath.

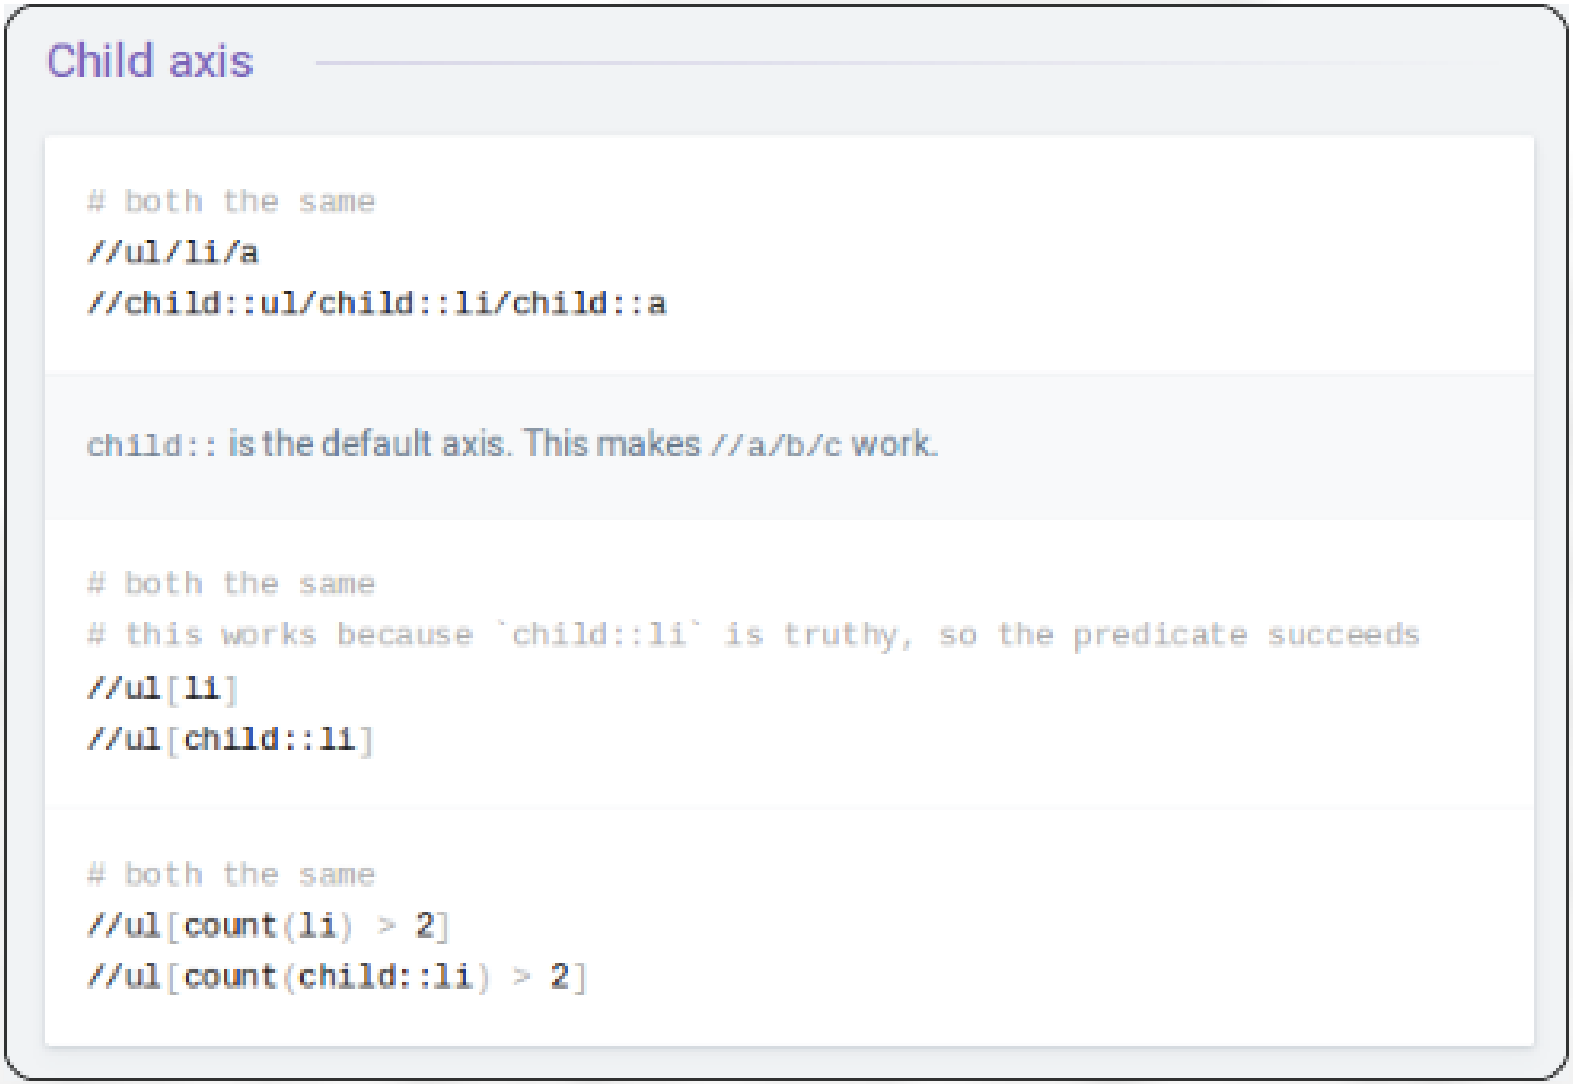

Figura 4. Seleção de filhos. Fonte: https://devhints.io/xpath.

Figura 5. Seleção de descendentes. Fonte: https://devhints.io/xpath.

Figura 6. Diferentes formas de caminho vertical e horizontal. Fonte: https://devhints.io/xpath.

Figura 7. Seleção de irmãos ou caminhos horizontais. Fonte: https://devhints.io/xpath.

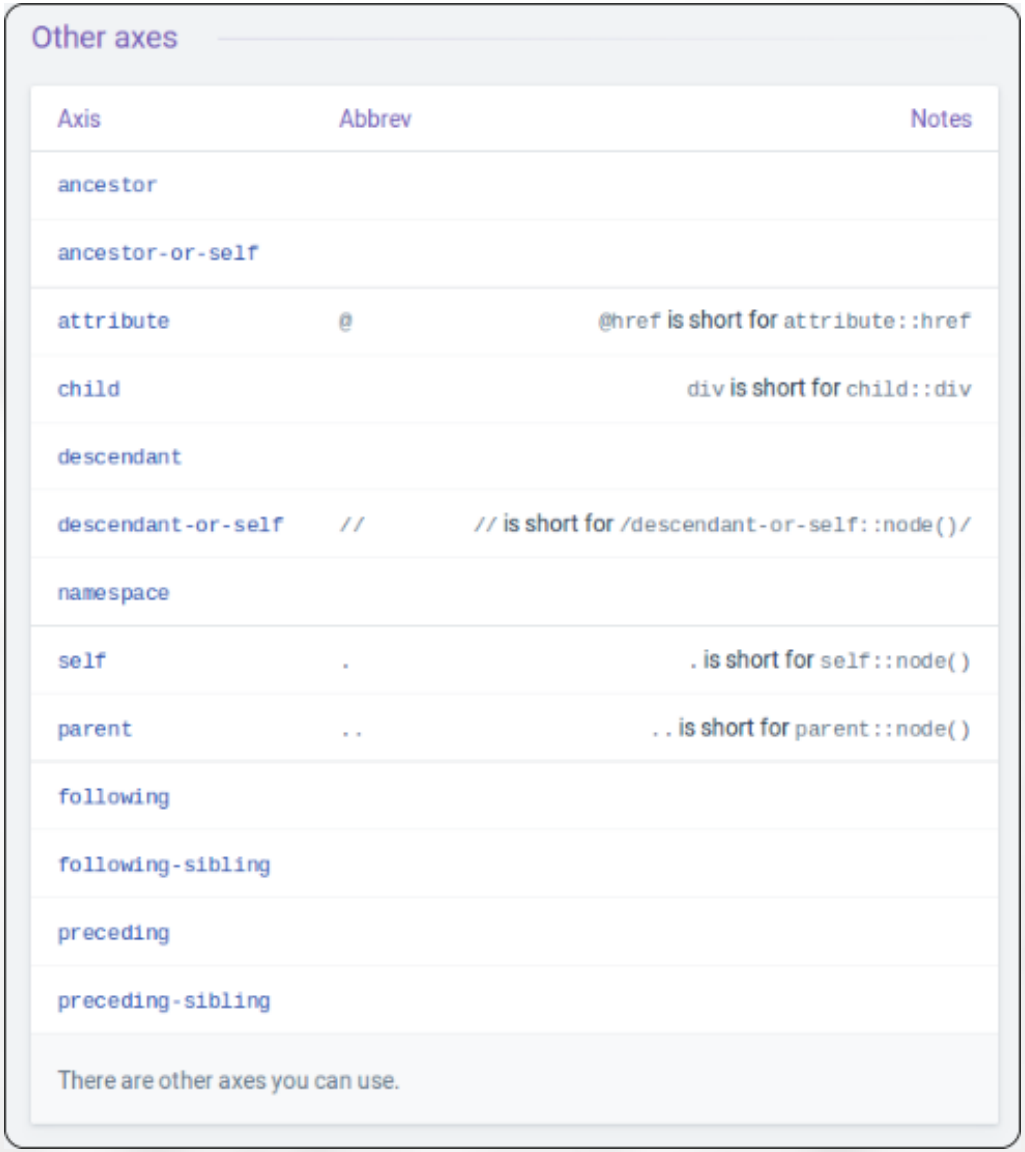

Other axes

Axis	Abbrev	Notes
`ancestor`		
`ancestor-or-self`		
`attribute`	`@`	`@href` is short for `attribute::href`
`child`		`div` is short for `child::div`
`descendant`		
`descendant-or-self`	`//`	`//` is short for `/descendant-or-self::node()/`
`namespace`		
`self`	`.`	`.` is short for `self::node()`
`parent`	`..`	`..` is short for `parent::node()`
`following`		
`following-sibling`		
`preceding`		
`preceding-sibling`		

There are other axes you can use.

Figura 8. Outras especificações de eixos verticais e horizontais. Fonte: https://devhints.io/xpath.

Attribute selectors

`#id`	`//*[@id="id"]`	?
`.class`	`//*[@class="class"]` …kinda	
`input[type="submit"]`	`//input[@type="submit"]`	
`a#abc[for="xyz"]`	`//a[@id="abc"][@for="xyz"]`	?
`a[rel]`	`//a[@rel]`	
`a[href^='/']`	`//a[starts-with(@href, '/')]`	?
`a[href$='pdf']`	`//a[ends-with(@href, '.pdf')]`	
`a[href*='://']`	`//a[contains(@href, '://')]`	
`a[rel~='help']`	`//a[contains(@rel, 'help')]` …kinda	

Figura 9. Seleção baseada nos atributos. Fonte: https://devhints.io/xpath.

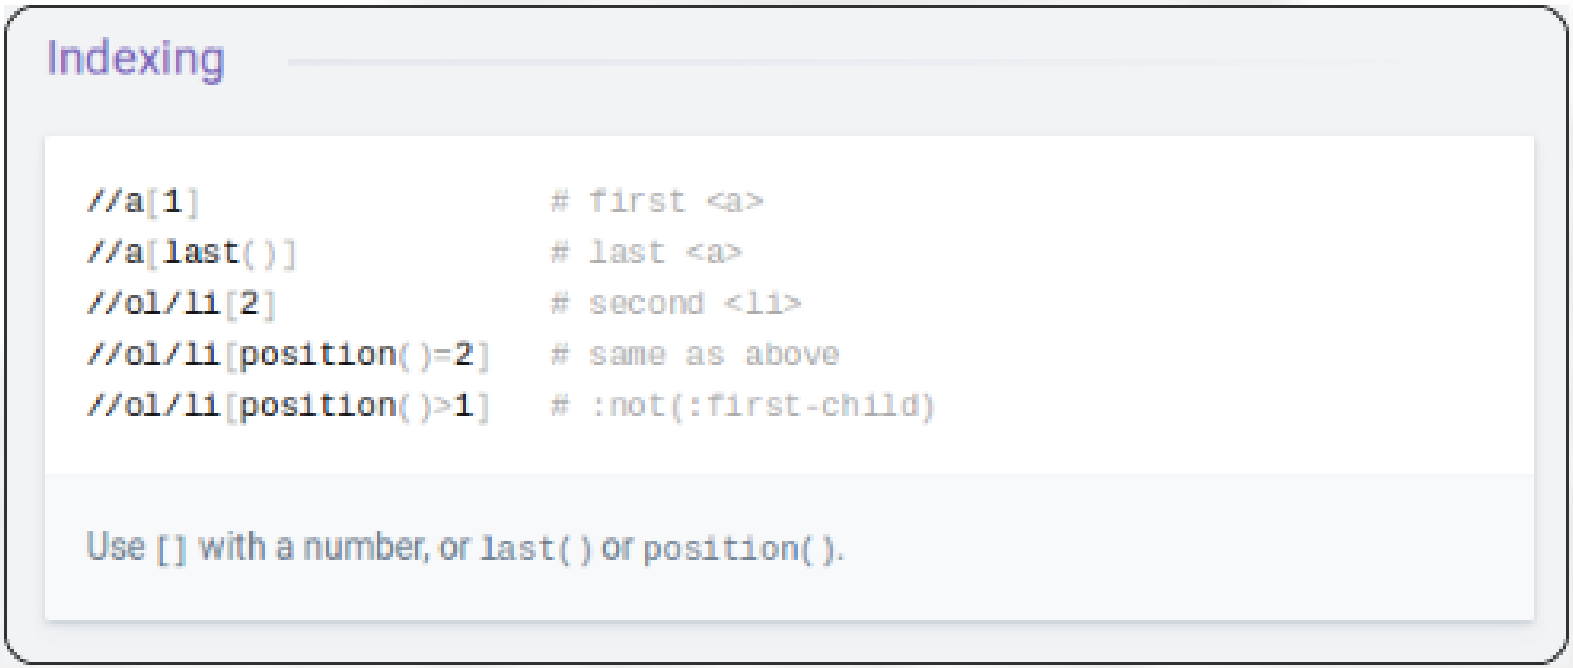

Figura 10. Seleção pela posição. Fonte: https://devhints.io/xpath.

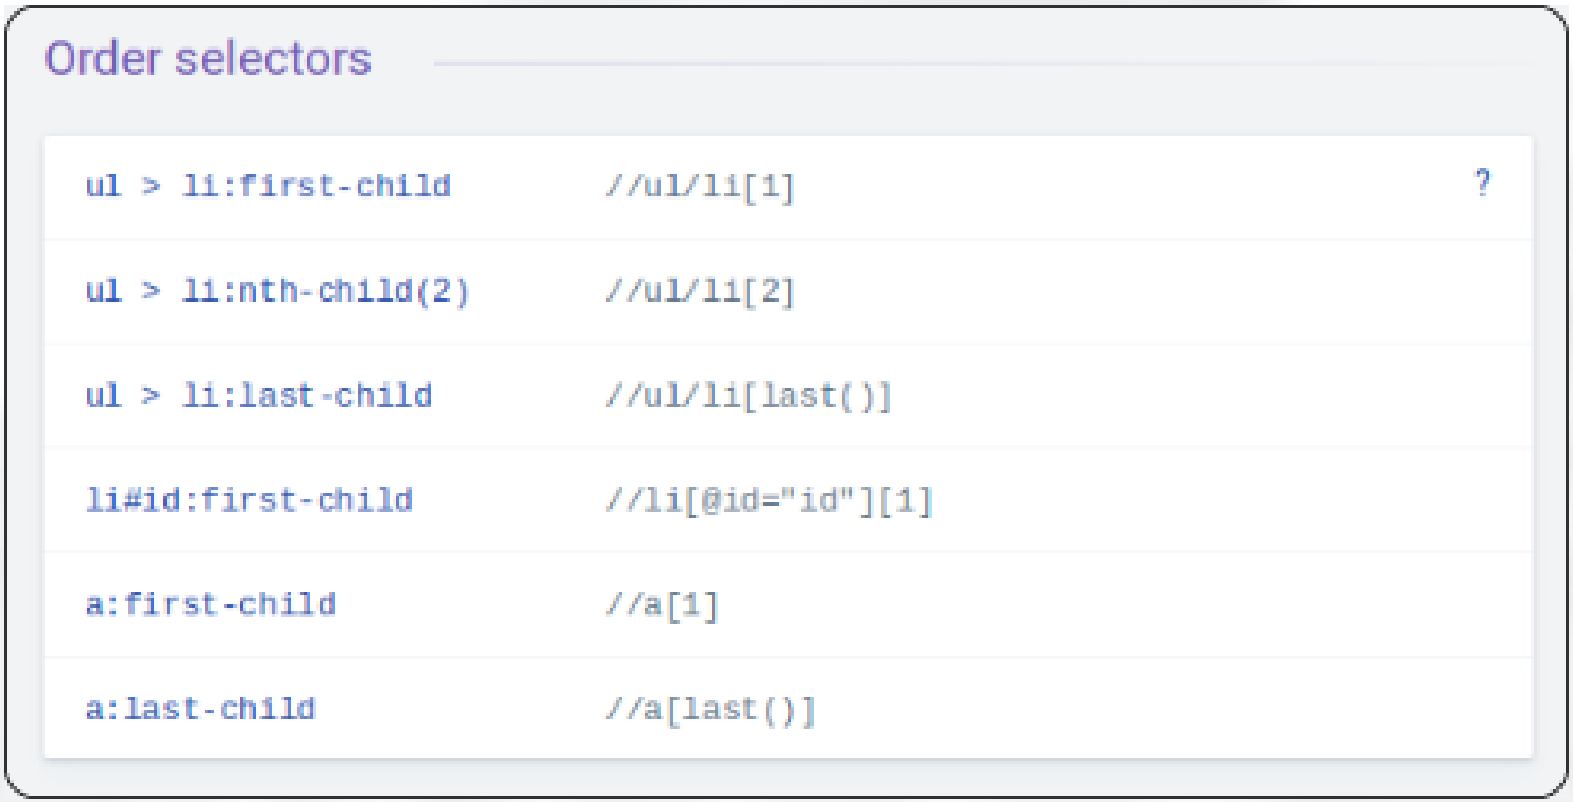

Figura 11. Mais seleção por posição. Fonte: https://devhints.io/xpath.

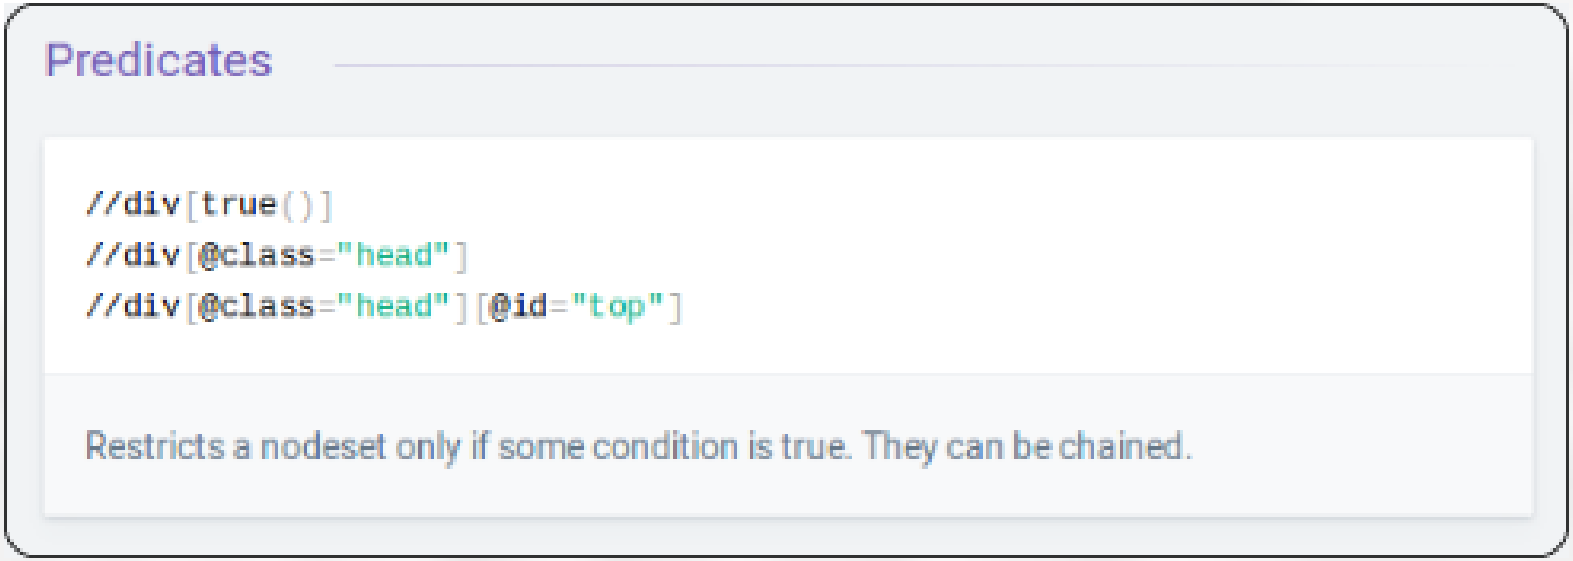

Figura 12. Uso de predicados nos nós. Fonte: https://devhints.io/xpath.

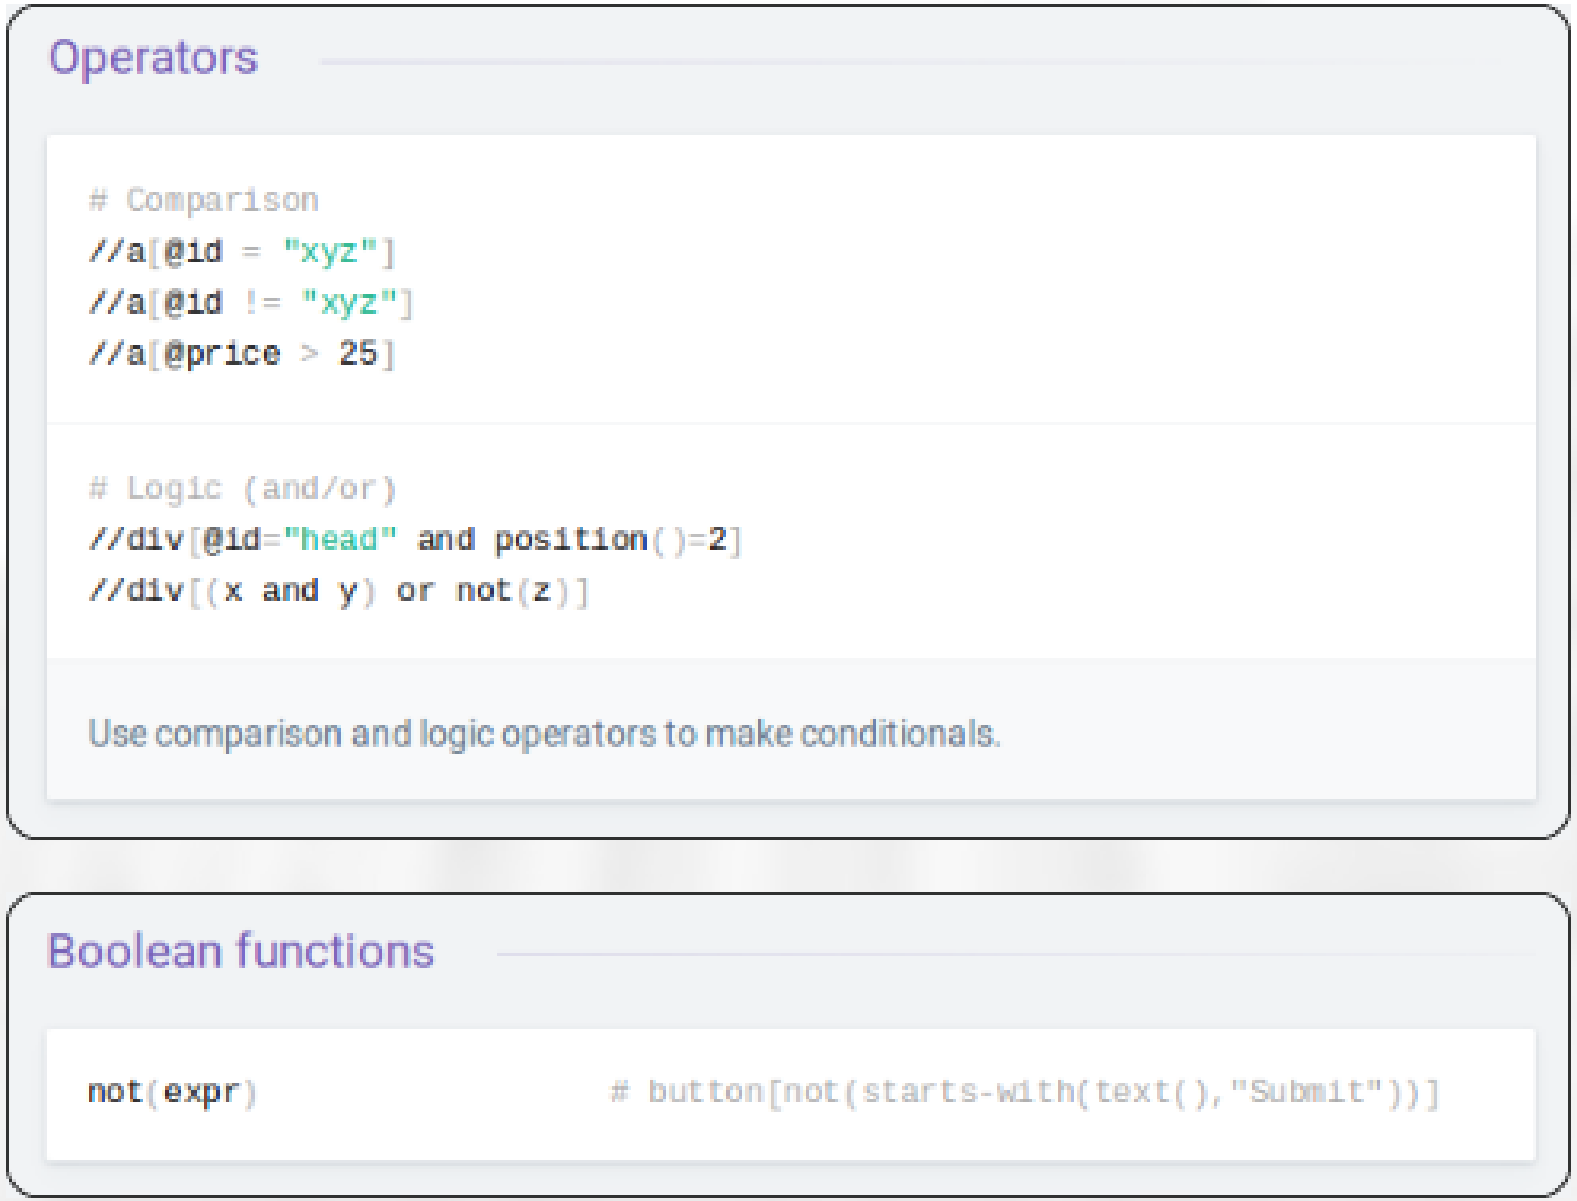

Figura 13. Operadores de comparação e lógicos. Fonte: https://devhints.io/xpath.

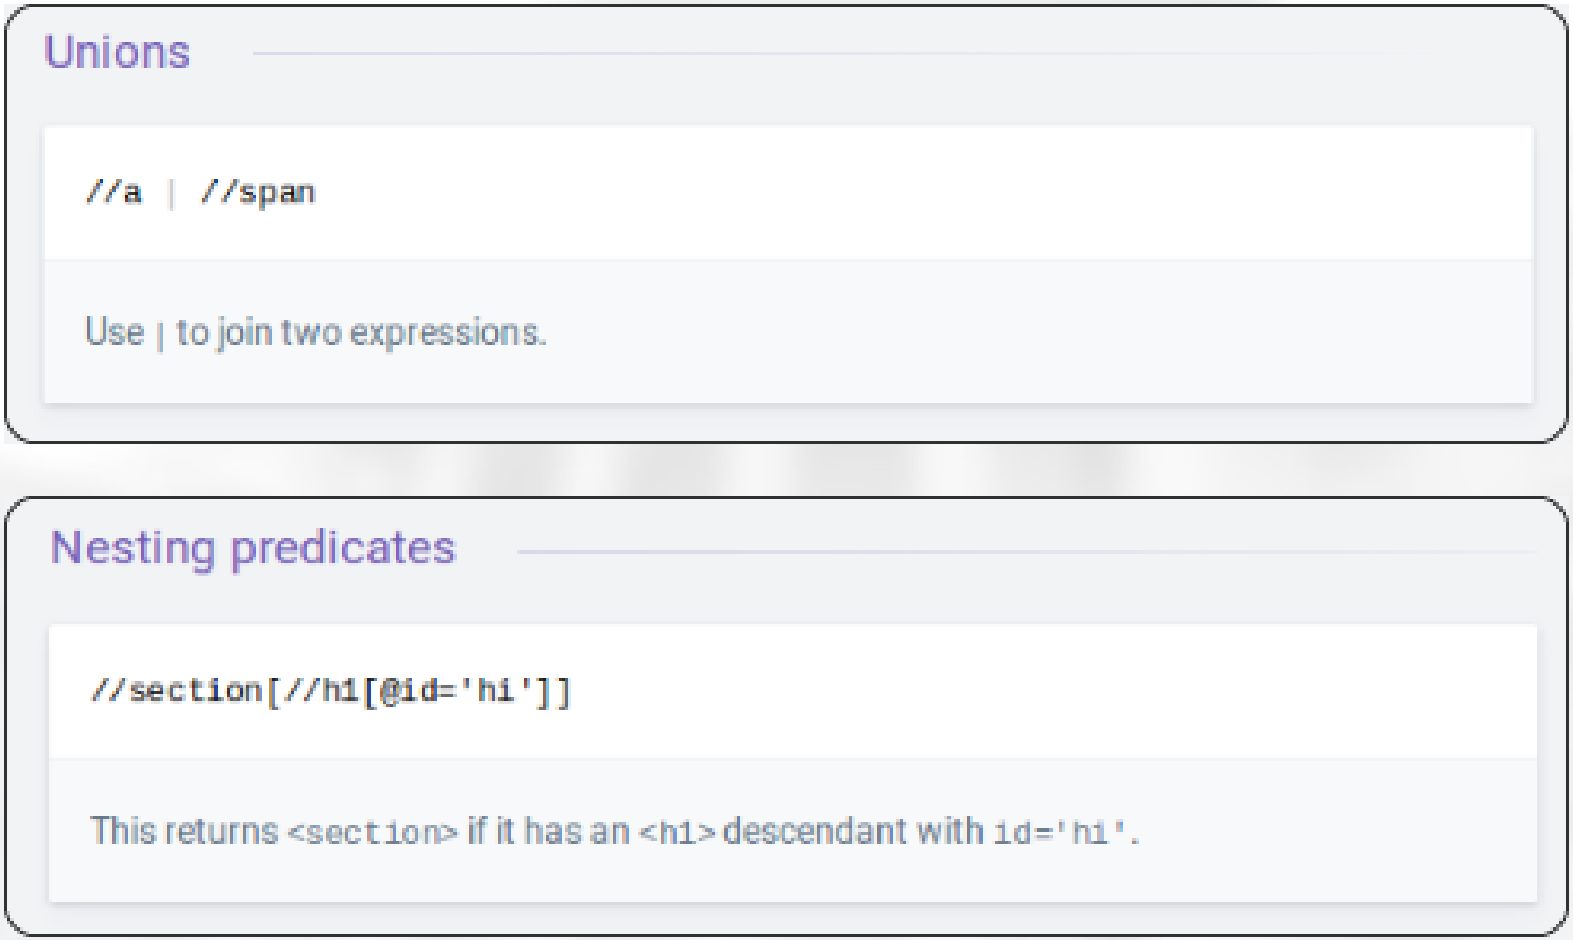

Figura 14. União de expressões e encadeamento. Fonte: https://devhints.io/xpath.

Node functions

```
name()                  # //[starts-with(name(), 'h')]
text()                  # //button[text()="Submit"]
                        # //button/text()

lang(str)
namespace-uri()


count()                 # //table[count(tr)=1]
position()              # //ol/li[position()=2]
```

Type conversion

```
string()
number()
boolean()
```

Figura 15. Funções aplicáveis aos nós. Fonte: https://devhints.io/xpath.

String functions

```
contains()                  # font[contains(@class,"head")]
starts-with()               # font[starts-with(@class,"head")]
ends-with()                 # font[ends-with(@class,"head")]

concat(x,y)
substring(str, start, len)
substring-before("01/02", "/")  #=> 01
substring-after("01/02", "/")   #=> 02
translate()
normalize-space()
string-length()
```

Figura 16. Funções de texto aplicáveis aos nós. Fonte: https://devhints.io/xpath.

Using nodes

```
# Use them inside functions
//ul[count(li) > 2]
//ul[count(li[@class='hide']) > 0]
```

```
# This returns `<ul>` that has a `<li>` child
//ul[li]
```

You can use nodes inside predicates.

Chaining order

```
a[1][@href='/']
a[@href='/'][1]
```

Order is significant, these two are different.

Figura 17. Combinando funções e precedência de seleção. Fonte: https://devhints.io/xpath.

Exemplos de uso do XPath

Usar esse conteúdo no http://xpather.com/ para avaliar expressões XPath.

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>.
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//span
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//ul[@class = 'ingredientes']/li
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//ul[last()]/li[position() < last() - 2]
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//ul/li[position() > 1 and position() < last()]
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//ul[count(li) = 4]
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//*[@class and not(./li)]
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//li[starts-with(text(), 'D')]
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//p/parent::div
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//div[./p]
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//p/ancestor::div
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

```
//span[contains(., 'reais') or contains(., 'pessoas')]
```

XML mode | Format | Save

```
<body>
  <div type="orçamento">
    <p>
      Essa sobremesa custa <span class="valor">10 reais</span>
      e serve <span class="quantidade">6 pessoas</span>
    </p>
  </div>
  <div type="sobremesa">
    <ul class="ingredientes">
      <li>3 ovos.</li>
      <li>150 ml de leite.</li>
      <li>3 colheres de manteiga.</li>
      <li>Massa preparada de bolo.</li>
    </ul>
    <ul class="preparo">
      <li>Deixe o forno preaquecer por 20 min a 180 graus.</li>
      <li>Bata os ingredientes até uniformizar.</li>
      <li>Unte a forma.</li>
      <li>Despeje na forma.</li>
      <li>Leve ao fogo por aproximadamente 1 hora.</li>
    </ul>
  </div>
</body>
```

Resumo de recursos do XPath

- Prefixos e eixos:
  - `./`, `/`, `//`.
  - Verticais: `child::`, `parent::`, `descendant::`, `ancestor::`, etc.
  - Horizontais: `following-sibling::`, `preceding-sibling::`.
- Metacacteres: `.`, `..`, `@`, `*`.
- Predicados: `[···]`.
- Operadores de comparação: =, !=, <, <=, >, >=.
- Operadores lógicos: `and`, `or`, `not()` e `|`.
- Funções: `text()`, `name()`.
- Funções numéricas: `count()`, `position()`, `last()`, etc.
- Funções de texto: `contains()`, `starts-with()`, etc.

Resumo

- XPath é uma linguagem **flexível e poderosa** para consultar XML/HTML.
- HTML são profundos na hierarquia e requerem uso de predicados para **delimitar a consulta**.
- O domínio dos recursos do XPath são fundamentais para especificar buscas precisas, fáceis de criar e manter.
- O emprego de predicados, eixos e funções potencializa a aplicação do XPath.
- O mesmo resultado pode ser conseguido com diversas expressões.
- Os predicados podem ser combinados de várias formas.
- Como expressões regulares, e necessário equilibrar **especificidade** e **generalidade** para reduzir manutenção do código.