

Reguläre Ausdrücke (Regular Expressions, kurz **RegEx**) werden häufig verwendet, um **HTML-Tags** zu erkennen, zu extrahieren, zu verarbeiten oder zu validieren. Im Folgenden Beispiele, die zeigen, wie reguläre Ausdrücke für HTML-Tags genutzt werden können, sowie Hinweise auf ihre Grenzen.

1. Einfache Erkennung von HTML-Öffnungstags

Dieser reguläre Ausdruck erkennt **öffnende HTML-Tags** (z. B. `<div>`, `<p>`, `<h1>`), unabhängig von den konkreten Tag-Namen.

RegEx:

```
<\s*[a-zA-Z]+\s*>
```

Erklärung:

- `<`: Start mit einem `<`-Zeichen (Tag-Start).
- `\s*`: Erlaubt beliebige Leerzeichen nach dem `<`.
- `[a-zA-Z]+`: Erfasst den Namen des Tags (z. B. `div`, `h1`, `p`), bestehend aus Buchstaben.
- `\s*`: Optionale Leerzeichen dürfen innerhalb des Tags stehen (z. B. `< div >`).
- `>`: Schließt das Tag mit einem `>`.

Beispiele:

- **Erkannt:** `<div>`, `<h1>`, ``
 - **Nicht erkannt:** `</div>` (Schließen), `` (enthält Attribute).
-

2. Erkennung von kompletten HTML-Tags (mit oder ohne Attribute)

Dieser reguläre Ausdruck erkennt **vollständige HTML-Tags**, einschließlich solcher mit Attributen.

RegEx:

```
<\s*[a-zA-Z]+\s*(\s+[a-zA-Z-]+\s*=\s*" .*?" )*\s*>
```

Erklärung:

- `<\s*[a-zA-Z]+`: Erkennung des Tag-Namens, wie oben beschrieben.
- `(\s+[a-zA-Z-]+\s*=\s*" .*?")*`: Optionaler Attributteil:
 - `\s+[a-zA-Z-]+\s*=\s*" .*?"`: Ein Attributname (z. B. `class`, `id`, `src`).
 - `\s*=\s*`: Optionaler Leerzeichen um das Gleichheitszeichen.
 - `" .*?"`: Gültiger Attributwert in Anführungszeichen.
- `\s*>`: Schließt das Tag.

Beispiele:

- **Erkannt:** `<div class="container">`, ``, `<input type="text" value="Hello">`
 - **Nicht erkannt:** `<div >some text</div>` (enthält geschachtelte Inhalte, für die andere Ansätze notwendig sind).
-

3. Erkennung von HTML-Schließtags

Dieser reguläre Ausdruck erkennt **schließende Tags** wie `</div>`, `</p>` usw.

RegEx:

```
</\s*[a-zA-Z]+\s*>
```

Erklärung:

- `</`: Ein Schließen beginnt mit `</`.
- `[a-zA-Z]+`: Der Name des Tags (wie `div`, `h1`, `body`).
- `\s*>`: Optionaler Leerzeichen und das Zeichen `>` schließen das Tag.

Beispiele:

- **Erkannt:** `</div>`, `</p>`, `</body>`
 - **Nicht erkannt:** `<div>` (öffnendes Tag).
-

4. Erkennung von Inhalten innerhalb von HTML-Tags

Dieser reguläre Ausdruck erkennt Inhalte zwischen einem **öffnenden und einem schließenden Tagpaar**, beispielsweise den Text zwischen `<p>` und `</p>`.

RegEx:

```
<\s*[a-zA-Z]+\s*>( .*? )</\s*[a-zA-Z]+\s*>
```

Erklärung:

- `<\s*[a-zA-Z]+\s*>`: Öffnendes HTML-Tag.
- `(.*?)`: Erfasst alles innerhalb der Tags (inklusive Leerzeichen); `?` stellt sicher, dass der "greedy mode" deaktiviert wird und der Reguläre Ausdruck nicht zu viel "schluckt".
- `</\s*[a-zA-Z]+\s*>`: Passendes schließendes HTML-Tag.

Beispiele:

- **Erkannt:** `<p>Hello World</p>`, `<h1>Title</h1>`
 - Erfasst dabei: „Hello World“, „Title“.
- **Nicht erkannt:** Ungeschlossene Tags wie `<p>Hello`.

5. Extrahieren nur bestimmter Tags (z. B. <a>-Tags)

Dieser reguläre Ausdruck extrahiert nur <a>-Tags (Hyperlinks), einschließlich ihrer Inhalte und Attribute.

RegEx:

```
<\s*a\b(?:\s+>)*(.*)</\s*a\s*>
```

Erklärung:

- `<\s*a\b`: Sucht explizit nach <a>-Tags (\b = Wortgrenze, um Tags wie <ab> auszuschließen).
- `(?:\s+>)*`: Erfasst alle Zeichen innerhalb des a-Tags, außer >, um Attribute mitzunehmen.
- `(.*)`: Erfasst die Inhalte (Text oder HTML) zwischen den Öffnungs- und Schließtags.
- `</\s*a\s*>`: Beendet das <a>-Tag.

Beispiele:

- **Erkannt:** `Click Me`
 - Erfasst den Inhalt: „Click Me“.
- **Nicht erkannt:** Andere Tags (z. B. `<p>` oder `<div>`).

6. Erkennung von selbstschließenden HTML-Tags

Dieser reguläre Ausdruck erkennt **selbstschließende HTML-Tags**, z. B. ``, `
`.

RegEx:

```
<\s*[a-zA-Z]+\s*(?:\s+\/?)>
```

Erklärung:

- `<\s*[a-zA-Z]+`: Erkennung des Tag-Namens.
- `(?:\s+\/?)>`: Optionale Attribute innerhalb des Tags.
- `/>`: Abschließendes > oder selbstschließendes />.

Beispiele:

- **Erkannt:** ``, `
`, `<input type="text" />`
- **Nicht erkannt:** Öffnungsschließ-Paare wie `<div>...</div>`.

7. Komplettes HTML-Dokument finden (Tags und Inhalte ignorieren)

Dieser reguläre Ausdruck matcht den groben Aufbau von **HTML-Dokumenten**, beginnend vom <html>-Tag bis zum </html>.

RegEx:

```
<\s*html\b(?:\s+>)*(.*)<\s*/\s*html\s*>
```

Erklärung:

- `<\s*html\b(?:\s+>)*`: Öffnendes <html>-Tag mit optionalen Attributen.
- `(.*)`: Alles innerhalb des <html>-Tags (HTML-Inhalt).
- `<\s*/\s*html\s*>`: Schließendes </html>-Tag.

Beispiele:

- **Erkannt:**

```
<html>
  <head><title>Test</title></head>
  <body>Hello</body>
</html>
```
- **Nicht erkannt:** Dokumente ohne schließendes </html>.

8. Erkennung aller HTML-Tags im Dokument

Dieser RegEx matcht **alle** HTML-Tags, unabhängig davon, ob sie öffnend, schließend oder selbstschließend sind.

RegEx:

```
<[>]+>
```

Erklärung:

- `<`: Start eines HTML-Tags.
- `[>]+`: Erfasst alle Zeichen bis zu einem >.
- `>`: Schließen des Tags.

Beispiele:

- **Erkannt:** `<div>, , </body>`.
 - **Nicht erkannt:** Text außerhalb von Tags, wie „Hello World“.
-

HINWEIS: Grenzen von RegEx bei HTML

Während Reguläre Ausdrücke nützlich für schnelle, einfache Aufgaben wie **Erkennen und Extrahieren von Tags** oder einfachen **Validierungen** sind, sollten komplexe Aufgaben mit spezialisierten **HTML-Parsern** (z. B. [BeautifulSoup in Python](#) oder DOM-Parser in JavaScript) erledigt werden. HTML ist rekursiv und erlaubt verschachtelte Strukturen, die RegEx zu verarbeiten sind.