

正規表現 クイックリファレンス

パターン、量指定子、グループ、先読み、フラグ

基本パターン

メタ文字

- `.` 任意の1文字 (改行を除く)
- `^` 文字列の先頭
- `$` 文字列の末尾
- `*` 直前の0回以上
- `+` 直前の1回以上
- `?` 直前の0または1回 (省略可能)
- `\` メタ文字のエスケープ

リテラルマッチング

```
hello # matches "hello" exactly
a.c   # matches "abc", "alc", "a-c", etc.
.txt  # matches literal ".txt"
```

文字クラス

ブラケット表現

- `[abc]` a, b, c にマッチ
- `[^abc]` a, b, c 以外にマッチ
- `[a-z]` 小文字アルファベット
- `[A-Z]` 大文字アルファベット
- `[0-9]` 数字
- `[a-zA-Z0-9]` 英数字

省略クラス

- `\d` 数字 `[0-9]`
- `\D` 非数字 `[^0-9]`
- `\w` 単語文字 `[a-zA-Z0-9_]`
- `\W` 非単語文字
- `\s` 空白 `[\t\n\r\f]`
- `\S` 非空白

量指定子

貪欲な量指定子

- `*` 0回以上 (貪欲)
- `+` 1回以上 (貪欲)
- `?` 0または1回 (貪欲)
- `{n}` ちょうど n 回
- `{n,}` n 回以上
- `{n,m}` n 回以上 m 回以下

怠情な量指定子

- `*?` 0回以上 (怠情/非貪欲)
- `+?` 1回以上 (怠情)
- `??` 0または1回 (怠情)
- `{n,m}?` n 回以上 m 回以下 (怠情)

怠情な量指定子はできるだけ少ない文字にマッチする

貪欲 vs 怠情

```
<.+> # greedy: "<b>bold</b>"
<.+?> # lazy: " <b>"
```

アンカー

- `^` 文字列の先頭 (`\m`` フラグで行の先頭)
- `$` 文字列の末尾 (`\m`` フラグで行の末尾)
- `\b` 単語境界
- `\B` 非単語境界
- `\A` 文字列の先頭 (`\m`` の影響を受けない)
- `\Z` 文字列の末尾 (`\m`` の影響を受けない)

アンカーの例

```
"Hello" # starts with "Hello"
worlds # ends with "world"
\bword\b # "word" as whole word
\bword\B # "word" inside another word
```

グループと選択

キャプチャグループ

```
(abc) # capture group: match "abc"
(a|b)c # alternation: a or b or c
(cat|dog) # match "cat" or "dog"
\d{3}-\d{4} # groups: "123-4567"
```

グループの種類

- `(pattern)` キャプチャグループ
- `(?:pattern)` 非キャプチャグループ
- `(?P<name>pat)` 名前付きグループ (Python)
- `(?<name>pat)` 名前付きグループ (JS, .NET)
- `\1 \2` グループ 1、2 への後方参照
- `a|b` 選択: a または b

先読みと後読み

- `(?=pattern)` 肯定先読み
- `(?!pattern)` 否定先読み
- `(?<=pattern)` 肯定後読み
- `(?<!pattern)` 否定後読み

先読み/後読みの例

```
\d+(?=USD) # digits followed by " USD"
\d+(?!USD) # digits NOT followed by " USD"
(?<=s)\d+ # digits preceded by "s"
(?<!s)\d+ # digits NOT preceded by "s"
```

先読み/後読みは文字を消費せずに位置にマッチする

よくあるパターン

- `\d{1,3}(\.\d{1,3}){3}` IPv4 アドレス (基本)
- `[w.+-]+@[w-]+\.[w.]+` メールアドレス (基本)
- `https?://[w./-?&#]=+` URL (基本)
- `\((\d{3})\)?[-.\s]\d{3}[-.\s]?[d{4}]` 米国の電話番号
- `\d{4}-\d{2}-\d{2}` 日付 (YYYY-MM-DD)
- `#?[0-9a-zA-F]{6}` 16 進カラーコード

これらは簡略化されたパターン。本番環境ではより厳密なバリデーションが必要な場合がある

フラグ

- `g` グローバル: 最初だけでなく全マッチを探索
- `i` 大文字小文字を区別しないマッチング
- `m` 複数行: `^`/`$` が行境界にマッチ
- `s` ドットオール: `.` が改行にもマッチ
- `x` 詳細モード: 空白を無視、コメントを許可
- `u` Unicode: 完全な Unicode サポート

言語別フラグの使用

```
/pattern/gi # JavaScript
re.compile(r"pat", re.I | re.M) # Python
grep -iE "pattern" # grep (extended)
```