



ALF

Expressions régulières et
Lexer

Keith Cooper, Linda Torczon, *Engineering a Compiler*

- Chapitre 2
 - 2.4
 - 2.5
 - 2.6

Alfred V. Aho, Monica S. Lam, Ravi Sethi, Jeffrey D. Ullman, *Compilers: Principles, Techniques, and Tools (2nd Edition)*

- Chapitre 3
 - 3.1
 - 3.3

Terence Parr, *The Definitive ANTLR 4 Reference*, (2nd Edition)

- Expressions régulières
- Lexer
- ANTLR



Donald Knuth



- Américain
- TeX *LATEX*
- The Art of Computer Programming
- Stanford

Expressions régulières

- Une façon de décrire la forme d'une string
- Les string sont reconnaissables par un automate fini
- Une string avec des caractères spéciaux

if / white / for


Syntaxe d'expression régulière

Character	Description	Exemple	String
* ✓	Zéro ou plusieurs fois	a^* , $(ab)^*$	aaaaaaaaa, ababababab
+ ✓	Une ou plusieurs fois	a^+ , $(ab)^+$	aaaaaaaa, ababababab
? ✓	Zéro ou une fois	$a^?$, $(ab)^?$	a, ab
^	début de string	$^ab^*$	abbbbbbb
\$	fin de string	$b^*a\$$	bbbba
. ✓	tout symbole	.	a, b, c
[]	Ensemble	<u>[abc]</u>	a, b
\s	Espace blanc	$a\s b$	a b
[^] ✓	ensemble complémentaire	$[^abc]$	e, d
() ✓	groupe	$(abc)^+$	Abcabcab
✓	Ou	$a b$, $(ab) (ba)$	a, ab


Automate fini pur a^*



a, ϵ, aa




Automate fini pur a+




Automate fini pur a?

$\Sigma = \{a\}$





a ✓
" ✓
" ✗




a ✓
" ✓


Automate fini pour $(abc)^*$



Automate fini pour $(abc)^+$



Automate fini pour (abc)?



Exemples

- Groupe →
- Téléphone
- Email
- Nom de variable
- Numéro entier
- Numéro avec virgule

122011FA1B|E
122[013]F[ABE]

FAGS / ((1|2) ... ((1|2)) [1234])

nom @ nom . nom

[012345]
[ABC ... Z]
[ABC ... Z]?
[A-Z]
[a-z]
[A-Za-z]

[A-Za-z0-9_\.|-]+@

[A-Za-z0-9_\.|-]+(\. |)

[A-Za-z0-9_\.|-]+)

JavaScript RegEx

let

```
var regex = new RegEx ('...');
```

let

```
var regex = /.../;
```

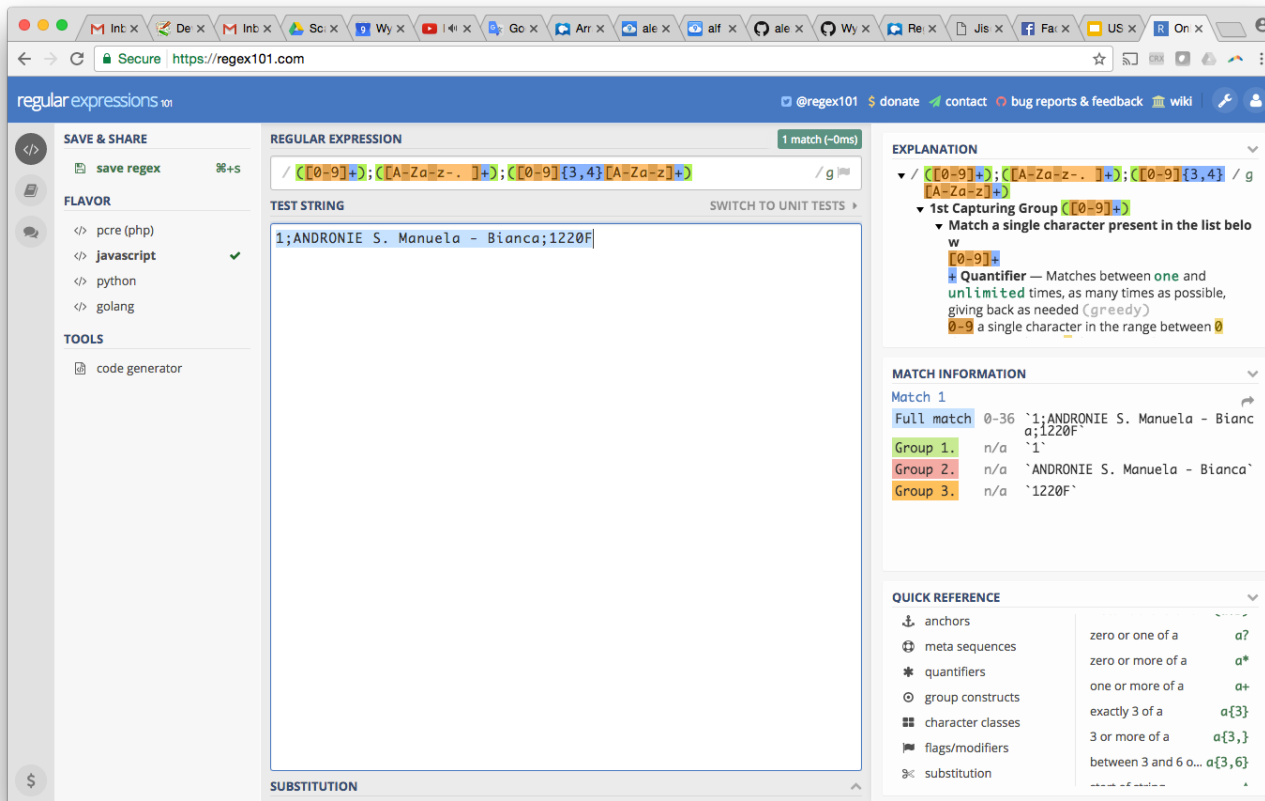
Documentation

[https://developer.mozilla.org/en/docs/Web/JavaScript/Guide/Regular Expressions](https://developer.mozilla.org/en/docs/Web/JavaScript/Guide/Regular_Expressions)

- RegEx
 - regex.exec (string)
 - Array
 - regex.test (string)
 - Boolean
- String
 - str.match (regex)
 - Array
 - str.search (regex)
 - Index of match

s. split /r?\n/

- <https://regex101.com> (vérificateur de regex)



The screenshot shows the regex101.com website interface. The regular expression being tested is `/([0-9]+);([A-Za-z-.]+);([0-9]{3,4}[A-Za-z]+)/g`. The test string is `1;ANDRONIE S. Manuela - Bianca;1220F`. The match information shows a full match at index 0-36 and three capturing groups: Group 1: `'1'`, Group 2: `'ANDRONIE S. Manuela - Bianca'`, Group 3: `'1220F'`.

Match	Index	Match
Full match	0-36	<code>`1;ANDRONIE S. Manuela - Bianca;1220F`</code>
Group 1.	n/a	<code>'1'</code>
Group 2.	n/a	<code>'ANDRONIE S. Manuela - Bianca'</code>
Group 3.	n/a	<code>'1220F'</code>

Syntaxe d'expression régulière (JS)

Character	Description	Exemple	String
{n}	n fois	a{3}	aaa
{n,m}	au moins n, au plus m	a{3,7}	aaa, aaaa
\w	alphanumérique et _	\w	a, ab
\t	TAB	^a\t*	a »TAB »a
\n	fin de ligne	a\nb	a b
\r	retour chariot	a\rb	a\rb
a(?!b)	a seulement si non suivi par b	a(?!b)	a, aa
a(?=b)	a seulement si suivi par b	a(?=b)	ab
()	group	a(ab)a	aaba

JavaScript Example

```
var regex = new Regex ('([0-9]+);([A-Za-z-\.  
]+);([0-9]{3,4}[A-Za-z]+)');
```

```
var regex = / ( ( [0-9] + ) ; ( [A-Za-z-\. ] + ) ; ( [0-9] { 3,4 } [A-  
Za-z] + ) /;
```


```
var match = regex.exec ('1;ANDRONIE S.  
Manuela - Bianca;1220F');
```

([0-9]+);([A-Za-z-\.\]+);([0-9]{3,4}[A-Za-z]+)

match:

```
[ '1;ANDRONIE S. Manuela - Bianca;1220F',  
  '1',  
  'ANDRONIE S. Manuela - Bianca',  
  '1220F',  
  index: 0,  
  input: '1;ANDRONIE S. Manuela - Bianca;1220F fdsfs' ]
```

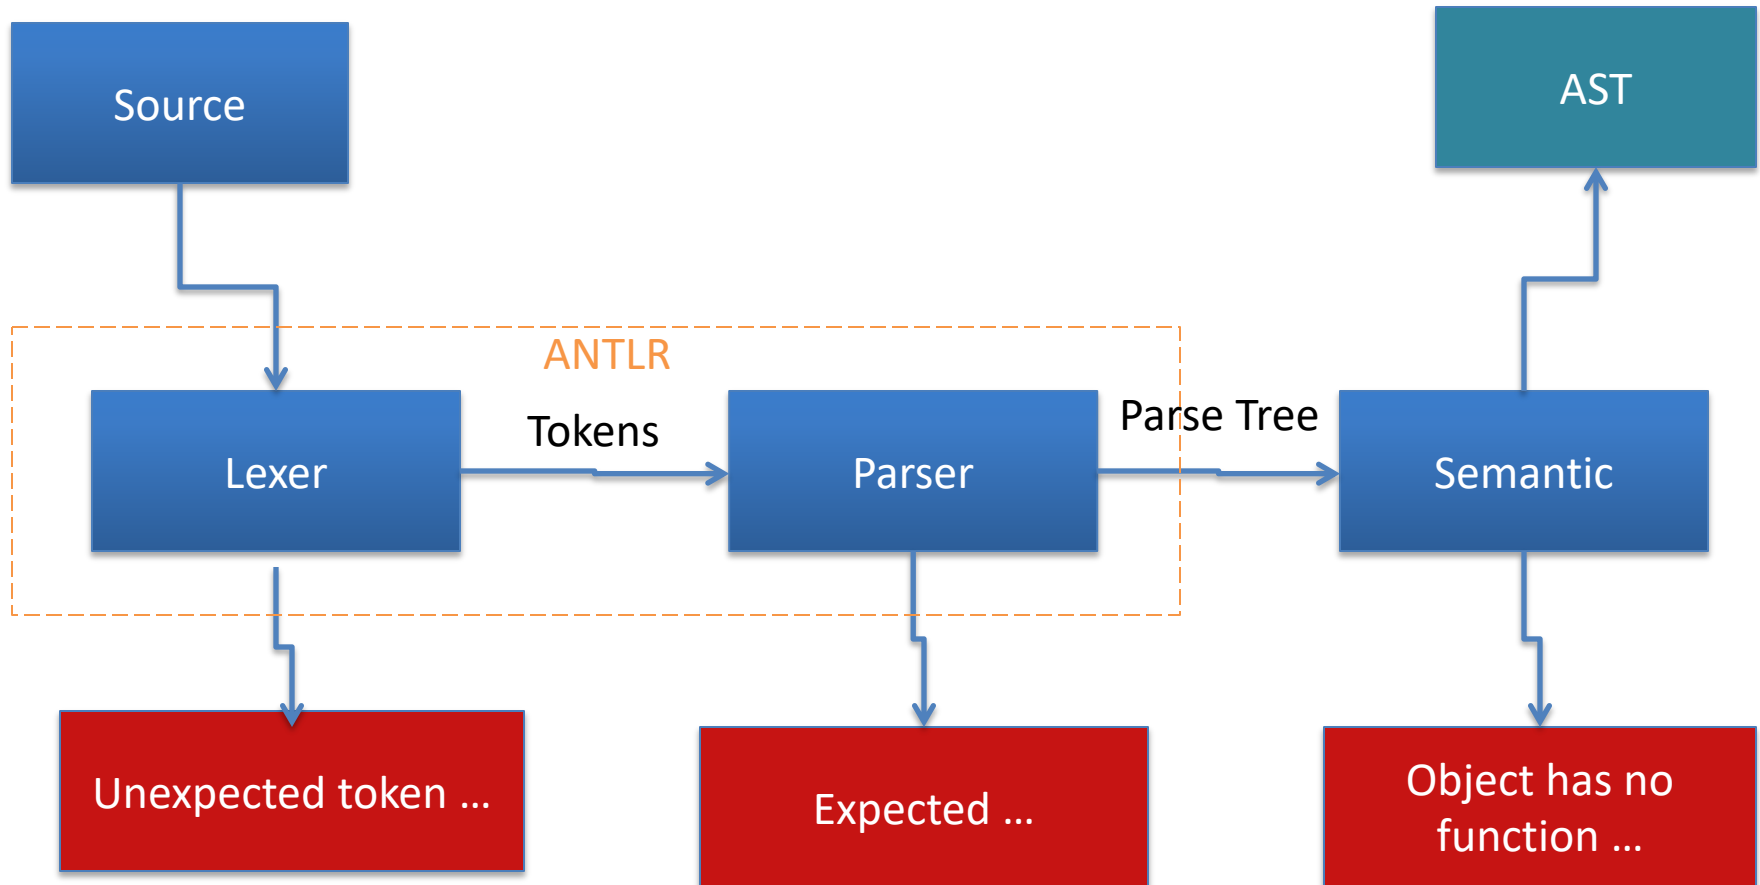
Lexer



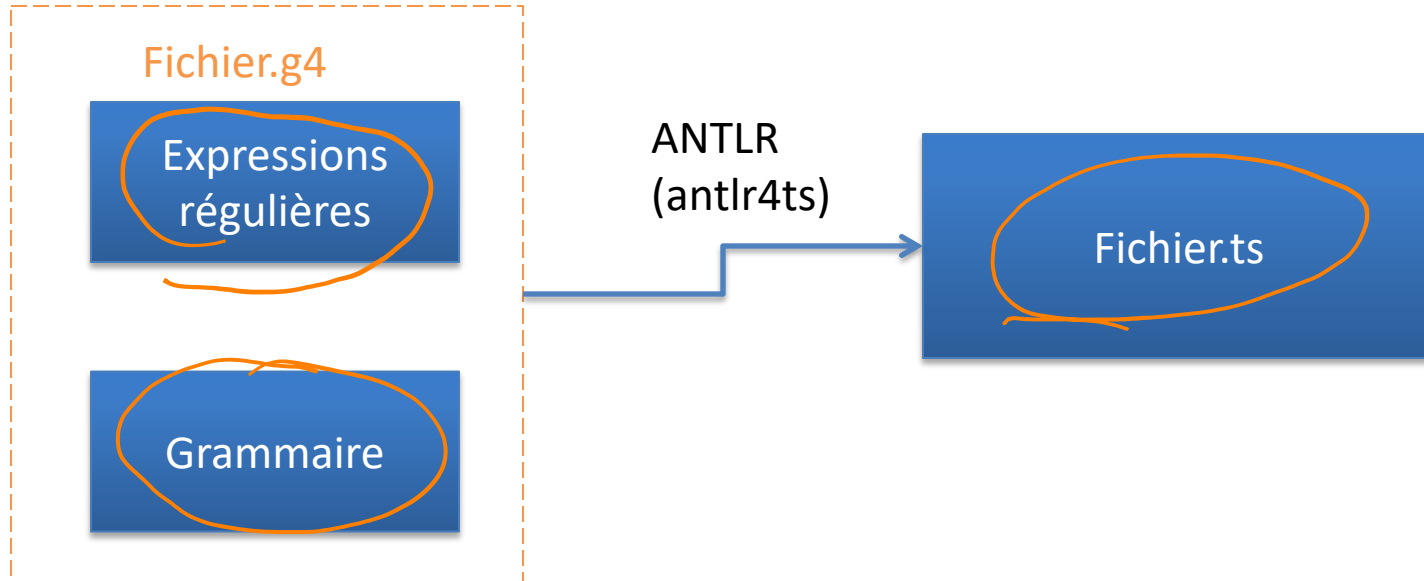


ANTLR

Frontent



Générateur de lexer/parseur



- Lexer
 - Expressions régulières
- Parser
 - Grammaire

Fichier.J (lex ou flex)

grammar Expr;

NEWLINE : [\r\n]+ ;
INT : [0-9]+ ;

prog: (expr NEWLINE)* ;
expr: expr ('*' | '/') expr
| expr ('+' | '-') expr
| INT
| '(' expr ')'
;

met
now

Fichier.g4

```
grammar Expr;
```

Nom

```
NEWLINE : [\r\n]+ ;
```

```
INT : [0-9]+ ;
```



Expressions Régulières

```
prog: (expr NEWLINE)* ;
```

```
expr: expr ('*' | '/') expr
```

```
      | expr ('+' | '-') expr
```

```
      | INT
```

```
      | '(' expr ')'
```

```
;
```

Règles de Grammaire

Nom

Expr. g4

grammar Expr;

Nom

Expression Régulières

Règles de Grammaire

Expressions Régulières

Nom

NEWLINE : `[\r\n]+` ;
INT : `[0-9]+` ;

Expressions Régulières

Règles de Grammaire

Règles de Grammaire

Nom

Expressions Régulières

```
prog: (expr NEWLINE)* ;  
expr: expr ('*' | '/') expr  
      | expr ('+' | '-') expr  
      | INT  
      | '(' expr ')'  
      ;
```

Règles de Grammaire

Expr.g4 (vide)

grammar Expr;

prog: ;



- Expressions régulières
 - Mathématique
 - JavaScript
- Lexer
- ANTLR

Questions

