

Expression Régulière

Plan du cours en 4 x 3h30

- OS & UNIX
- Prise en main d'un système Unix (term)
- Système de fichiers Unix
- Un éditeur de texte (vi)
- Expressions Régulières (regex)
- Processus (proc)
- Langages de commandes (shell)
- Le monde unix (X, net, ssh, ftp, http, mail,...)

Expression Régulières

Regex

- KEZACO REGEX
- Les méta caractères . * + ?
- Contre-oblique et classe de caractères
- Méta-caractères Positionnels
- Pattern Group
- Exemple

```
^[a-zA-Z][\w\.-]*[a-  
-zA-Z0-9]@[a-zA-Z0-  
9][\w\.-]*[a-zA-Z0-  
9]\.[a-zA-Z][a-zA-Z  
\.]*[a-zA-Z]$
```

Les expressions régulières

regex

KEZAKO regex

Recherche de motif dans un flux de texte :

Pattern (motif) Match(trouve) Structure(stockage)

Act(replace, delete,...)

Ensemble de conventions (meta caractères) utilisables dans tous les outils de développement pro (python, java, c, js, ...)

Mais aussi dans les outils mails, web, ...

Exemple : `egrep 'chapitre [1-6]' roman.txt`

Ne pas confondre avec les jokers du shell :

* : shell = ensemble de fichiers du repertoire

* : regex = répétition 0 à n du prochain caractère

Les expressions régulières

regex

Les meta caractères

. : peut-être n'importe quel caractère

Quantificateurs	Signification
?	Répète un caractère zéro ou une fois
*	Répète un caractère zéro ou plusieurs fois
+	Répète un caractère une ou plusieurs fois

Quantificateurs	Signification
{n}	Répétition n fois consécutives
{n,m}	Répétition de n à m fois consécutives
{,n}	Répétition de zéro à n fois consécutives
{n,}	Répétition au moins n fois consécutives

Exemple :

a{1,3} => a, aa, aaa et rien d'autre

abc{2,4}d => abccd, abcccd, abccccd et rien d'autre

a.{2,2}z ou a.{2}z => abcz, aXXz, ak0z, ...

Les expressions régulières

regex

Les meta caractères contre oblique \

Utile quand on veut utiliser les meta caractères pour ce qu'ils sont

`article\.txt => recherche article.txt`

Ne match pas avec `articlestxt`

Difficulté : décrire le bon motif qui correspond à la recherche

Chercher Qui ou qui avec `.ui` n'est pas pertinent

Au plus on utilise de méta-caractères :

- au plus on est selectif
- au plus on est difficile à relire

Les expressions régulières

regex

Pour tester : <https://www.regextester.com/>

RegEx Testing
From Dan's Tools

▼ Web Dev ▼ Conversion ▼ Encode/Decoders

Regular Expression

Javascript ▼

flags

/article^[^02][ab]\.txt/g

2 matches

Test String

article1a.txt article2a.txt article1c.txt article9a.txt

Substitution

\n# \$&:\n\t

article1a.txt:
article2a.txt article1c.txt

Regular Expression / /g
g pour global pour tout ce qui match

Les expressions régulières

regex

Les meta caractères les classes []

[] précise l'ensemble des . acceptés

article[0-3][a-c]\.txt match article0a.txt article2b.txt ...

La notion d'exclusion ^ en 1ere position de la classe

article[^02][ab]\.txt => article1a.txt article3b.txt

Au plus on utilise de méta-caractères :

- au plus on est selectif
- au plus on est difficile à relire

Les expressions régulières

regex

Les meta caractères de position

`\.txt$` => tout ce qui termine par `.txt`

`.txtexemple.h` ne sera pas sélectionné

`grep -c -e '^$' doc.txt` retourne le nombre de ligne vide

.

L'alternative `x|y` permet un choix `x` ou `y`

`^ (De|Sujet|Date) : @`

Permet de matcher `De : @` ou `Sujet : @` ou `Date @`

Les expressions régulières

regex

Caractère	Traduction en langage regex
^	début d'une ligne
\$	fin d'une ligne
.	Correspond à n'importe quel caractère
\s	Correspond à un espace
\S	Correspond à n'importe quel caractère sauf l'espace
*	Répète un caractère zéro ou plusieurs fois
+	Répète un caractère une ou plusieurs fois
[aeiou]	Correspond à un caractère unique de la liste des caractères indiqués
[^XYZ]	Correspond à un caractère unique qui n'est pas dans la liste XYZ
[a-z0-9]	Lettres minuscules de A à Z ou chiffres de 0 à 9
\w	Correspond à n'importe quel caractère alphanumérique ([a-zA-Z0-9_])
\W	Correspond à n'importe quel caractère non alphanumérique ([^a-zA-Z0-9_])
\d	Correspond à n'importe quel caractère numérique
\D	Correspond à n'importe quel caractère non numérique
(	Indique le début de l'extraction de la chaîne
)	Indique la fin de l'extraction de la chaîne
R S	L'expression régulière R ou S

Les expressions régulières

regex

Regular Expression

JavaScript ▾ flags

/art(.[^_]*)(.*)_\.txt\$/g

1 match

Test String

article_1a.txt

Substitution

⊖

\n# \$&; \$1; \$2;\n\t

article_1a.txt; icle; 1a;

Les group Pattern ()

Utiliser dans les expressions de substitution

Permet de récupérer sous forme de variable des groupes

Permet de remplacer des sequence par d'autres

Les expressions régulières

regex

Commande sed idem vi mais en stream de texte

`\.txt$` => tout ce qui termine par `.txt`

`.txtexemple.h` ne sera pas sélectionné

`grep -c -e '^$' doc.txt` retourne le nombre de ligne vide

.

L'alternative `x|y` permet un choix `x` ou `y`

`^ (De|Sujet|Date) : @`

Permet de matcher `De : @` ou `Sujet : @` ou `Date @`