
# L'ambiente UNIX/Linux

## Espressioni regolari e comando find

Stefano Quer
Dipartimento di Automatica e Informatica
Politecnico di Torino

# Espressioni regolari

- Nate nel 1956 a opera del matematico Stephen Cole Kleene nel dominio degli automi e dei linguaggi formali
- Utilizzate ampiamente a partire dagli anni '70 in ambienti UNIX per
  - Ambienti di editing (vi, emacs, etc.)
  - Comandi di shell (find, grep, etc.)
  - Linguaggi di scripting (SED, AWK, Perl, Python, etc.)

# Espressioni regolari

- Standardizzate da POSIX nel 1992
- Ne esistono diverse versioni, con formalismi distinti, simili ma **non** identici
  - BRE, Basic Regular Expression
  - ERE, Extended Regular Expression
  - PCRE, Perl Compatible Regular Expression
    - Libreria C di Regular Expression (Hazel, 1997)
    - Molto più flessibili e potenti della versione POSIX
    - Diventato uno standard de-facto con Perl 5
- Nel corso di SO
  - Ne faremo un uso superficiale con find, grep, scripting di shell, etc.

# Espressioni regolari

- Una espressione regolare (o **pattern**) è una espressione utilizzata per specificare un insieme di stringhe
  - Operatori compatti sono utilizzati per rappresentare sequenze complesse
    - Esempi
      - a | b* indica l'insieme delle stringhe {a, $\phi$, b, bb, bbb, bbbb, …}
      - \d\.\d i numeri decimali con una sola cifra intera (\d), il punto decimale (\.) e una sola cifra decimale (\d), ovvero {0.0, 0.1, 0.2, …, 9.8, 9.9}

# Espressioni regolari

- Le espressioni sono utilizzate per effettuare l'accoppiamento (**match**) tra oggetti
  - Nomi di direttori, nomi di file, righe o campi di file, stringhe o sotto-stringhe, etc.
- In generale quindi
  - Occorre capire quali caratteristiche identificano univocamente gli oggetti che si desidera manipolare
  - Esperimere tali caratteristiche con una espressione regolare

# Espressioni regolari e automi

- Una espressione regolare corrisponde a un Automa Non Deterministico
  - NFA (Nondeterministic Finite Automata)

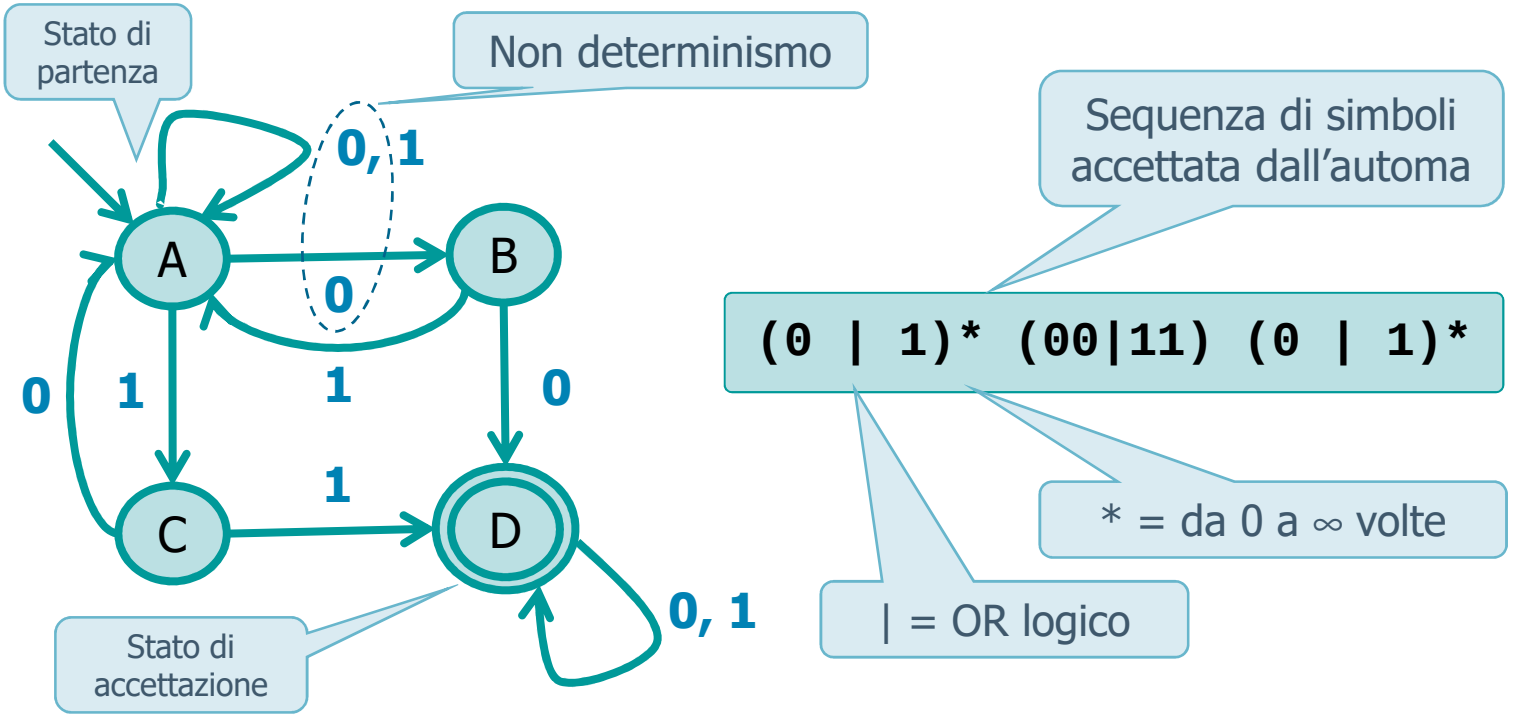

# Definizioni base

- Letterale
  - Qualsiasi carattere (o sequenza di caratteri) utilizzato nella ricerca del match
    - ind in w**ind**ows, **ind**ifferent, etc.
- Metacarattere
  - Uno o più caratteri con significato speciale
    - * indica da 0 a ∞ simboli precedenti, e.g., b* = {ϕ, b, bb, bbb, …}
- Sequenza di escape
  - Metodo per indicare che un metacarattere deve essere utilizzato come letterale
    - Il carattere '.' si indica con '\.'

La potenza della RE è nascosta nell'utilizzo dei metacaratteri

'\n' = new-line (n non è un metacarattere)

# Metacaratteri

| Operatore | Significato |
|---|---|
| [...] | Specifica un elenco o un intevallo di simboli |
| (...) | Gestisce la precedenza tra operatori<br>Raggruppa insiemi di simboli in sottoespressioni<br>Permette riferimenti a espressioni precedenti (backward reference) |
| \| | Effettua l'OR tra espressioni regolari |

Basic RE: \[...\] e \(...\)

| Ancore | Significato |
|---|---|
| \< | Inizio parola |
| \> | Fine parola |
| ^ | Inizio riga |
| $ | Fine riga |

| Caratteri speciali | Significato |
|---|---|
| \+ \? \. * | Char '+', '?', '.', '*' |
| \n | New line |
| \t | Tabulazione |

# Metacaratteri

| Quantificatori e Intervalli | Significato |
|---|---|
| * | Elemento presente [0, ∞] volte |
| + | Elemento presente [1, ∞] |
| ? | Elemento presente [0, 1] volte |
| $[c_1c_2c_3]$ | Uno qualsiasi dei caratteri in parentesi |
| $[c_1\text{-}c_2]$ | Uno qualsiasi dei caratteri nel range |
| $[\hat{}c_1\text{-}c_2]$ | Uno qualsiasi dei caratteri non nel range |
| {n} | Elemento presente esattamente n volte |
| $\{n_1,n_2\}$ | Elemento presente da $n_1$ a $n_2$ volte |

Sovra-insieme

Comando grep:
ammette anche le versioni $\{n_1,\}$ ovvero $\{,n_2\}$

# Metacaratteri

| Caratteri | Significato |
|---|---|
| c | Un qualsiasi simbolo c<br>(Tranne quelli utilizzati a scopi speciali) |
| . | Un carattere qualsiasi (non '\n') |
| \s | Uno spazio o una tabulazione |
| \d | Una cifra 0-9 |
| \D | Non una cifra |
| \w | Qualsiasi carattere tra 0-9, A-Z, a-z |
| \W | Qualsiasi carattere non in 0-9, A-Z, a-z |

Sovra-insieme
(non tutti sono disponibili
per tutti i comandi)

# Esempi

| RE | Significato |
|---|---|
| ABCDEF | La stringa "ABCDEF" |
| a*b | Un qualunque numero di a seguite da una b |
| ab? | Solo a oppure ab |
| a{5,15} | Da 5 a 15 ripetizioni della lettera "a" |
| (fred){3,9} | Da 3 a 9 ripetizioni della stringa "fred" |
| .+ | Qualsiasi sequenza non vuota (una riga) |
| myfunc.*(.*) | Una funzione il cui nome inizia per "myfunc" |
| ^ABC.* | Una riga che inizia con "ABC" |
| .*h$ | Una riga che finisce con "h" |
| hello\> | Una parola che termina con "hello" |
| a+b+ | Una o più a seguite da una o più b |

# Esempi

| RE | Significato |
|---|---|
| [a-zA-Z0-9] | Una lettera o una cifra |
| A\|b | A oppure b |
| \w{8} | Sequenza di 8 caratteri alfabetici o numerici (minuscoli o maiuscoli) |
| ((4\.[0-2])\|(2\.[1-3])) | Numeri 4.0, 4.1, 4.2 oppure 2.1, 2.2, 2.3 |
| (.)\1 | Due caratteri identici |
| (.)(.).\2\1 | Qualsiasi stringa palindroma di 5 caratteri (e.g., radar, civic, 12321, etc.) |

\1, \2
Backward Reference

Basic RE: \(.\)\1 e\(.\)\(.\).\2\1
Extended RE: (.)\1 e (.)(.).\2\1

# Esercizio

- Scrivere una espresione regolare per rintracciare
  - Una qualsiasi data con formato gg/mm/aaaa
    - Giorno e mese possono essere espressi su 1 o 2 cifre

```
\d{1,2}\/\d{1,2}\/d{4}
```

  - Tutte le righe che contengono un solo numero intero incluso tra 1 e 50 (inclusi)

```
(^[1-9]$|^[1-4][0-9]$|^50$)
```

# Il comando find

- Permette di
  - Ricercare file, direttori o link che soddisfano (match) un particolare criterio, creandone un elenco
  - Se necessario, eseguire sugli oggetti dell'elenco dei comandi di shell
- Osservazione
  - Il commando ritorna il path (relativo) degli oggetti rintracciati non (solamente) il loro nome
  - Questo è importante per la scrittura delle espressioni regolari di ricerca e delle azioni da effettuare

# Il comando find

```
find direttorio [opzioni] [azioni]
```

- Il formato del commando risulta relativamente complesso
- Sostanzialmente
  - Visita tutto l'albero a partire dal direttorio **directorio**
  - Crea l'elenco che soddisfa le **opzioni**
  - Eventualmente effettua per ogni file le **azioni** specificate
- Occorre analizzare come specificare directory, options e actions

# Specifica del direttorio

- Direttorio
  - Specifica l'albero di direttori in cui eseguire il commando
  - Esempi
    - .
    - /usr/bin
    - ./subDirA/subDirB

```
find directorio [opzioni] [azioni]
```

# Specifica delle opzioni

- Opzioni

| Opzione | Significato |
|---|---|
| -name pattern | Match con il nome del file.<br>Il path iniziale è rimosso.<br>In alcune versioni è possibile racchiudere il pattern tra doppi apici per specificare espressioni regolari.<br>**-iname** è identica ma case insensitive. |
| -path pattern | Come il precedente ma specifica path + nome<br>**-ipath** è identico ma case insensitive. |

```
find directorio [opzioni] [azioni]
```

# Specifica delle opzioni

| Opzione | Significato |
|---|---|
| -regex expr | Specifica una espressione regolare che deve avere un match con il path (completo) rintracciato.<br>**-iregex** è identica ma case sensitive. |
| -regextype type | Indica il tipo di RE utilizzate, ovvero: posix-basic, posix-egrep, posix-extended, etc.<br>Occorre specificare il tipo prima della RE (**regextype** va inserito prima di **regex**). |
| -atime [+,-]n<br>-ctime [+,-]n<br>-mtime [+,-]n | Ultimo access, status o modification time.<br>n=1 specifica da 0 a 24 ore fa.<br>Il valore di n può essere inserito con segno:<br>+ indica ≤, - indica ≥ |

```
find directorio [opzioni] [azioni]
```

# Specifica delle opzioni

| Opzione | Significato |
|---|---|
| -size [+,-]n[bckwMG] | Dimensione del file.<br>Il segno + indica ≥, quello - indica ≤.<br>Il carattere successivo indica l'unità di misura:<br>• b blocchi (di 512 byte)<br>• c byte<br>• k kByte<br>• w word (2 byte)<br>• M Mbyte<br>• G GByte |
| -type tipo | Tipo di file. Il tipo può essere: **f** per file regolari (i.e., file di testo, eseguibili, etc.), **p** per pipe, **l** per symbolic link, **s** per socket, **d** per direttori |

```
find directorio [opzioni] [azioni]
```

# Specifica delle opzioni

| Opzione | Significato |
|---|---|
| -user nome<br>-group nome | Definizione del proprietario del file, ovvero identificativo del proprietario (**user**) oppure del gruppo (**group**) |
| -readable<br>-writable<br>-executable | Modalità di accesso, ovvero l'oggetto deve essere leggibile, scrivibile, eseguibile |
| -mindepth n<br>-maxdepth n<br>-quit | Sezione dell'albero in cui effettuare la ricerca: **mindepth** indica la profondità minima per la ricerca (nell'albero di direttori) e **maxdepth** quella massima. Con **quit** esce dalla ricerca dopo il primo match. |

```
find directorio [opzioni] [azioni]
```

# Esempi: find & options

```
find . -name "*.c"
```

File c con qualsiasi nome (uso wildchar dos)

```
find . -regex "*.c"
```

Errato: *.c non è una RE

```
find . -regex ".*\.c"
```

RE equivalente

```
find /usr/bin -iname "a.*"
```

Tutti i file con nome uguale ad a oppure A e hanno una estensione qualsiasi

Tutti i file di dimensione >500 Byte

```
find . -size +500c
```

Tutti i file leggibili nel direttorio corrente (./) con nome che inizia per ab, aab, aaab e qualsiasi estensione

```
find . -readable \
  -regex "\./a+b.*\..*"
```

# Esempi: find & options

```
find /usr/bin \
  -regextype posix-extended \
  -regex ".*\/..(.)(.).\2\1.*"
```

Tutti i file con nome costituito da due caratteri iniziali, sequenza palindroma di 5 caratteri e altri caratteri in numero indefinito

```
find /usr/bin -regex \
  ".*\/..\(.\)\(.\).\2\1.*"
```

Idem ma con RE standard

Tutti i file di estensione exe nel direttorio /home/usr dal livello 2 al 4 (inclusi)

```
find /home/usr/ \
  -mindepth 2 -maxdepth 4 \
  -name "*.exe"
```

# Specifica delle azioni

- Azioni
  - L'azione di default del commando **find** è la stampa
    - L'azione di default equivale al commando **print**

```
find directorio [opzioni] -print
```

  - È però possibile eseguire
    - Un qualsiasi comando di shell
    - Su ciascuno degli oggetti appartenenti all'elenco restituito

```
find directorio [opzioni] [azioni]
```

# Specifica delle azioni

| Azione | Significato |
|---|---|
| -print | Azione di default. Stampa un nome per ciascuna riga |
| -fprint | Come il predente ma effettua l'output su file |
| -print0 | Come –print ma non va a capo |
| -execdir command | Esegue il commando |
| -exec command | Versione sicura POSIX dell'azione precedente. Espande il commando includendo il path e il nome. |
| -delete | Elimina l'oggetto rintracciato |

# Specifica delle azioni

- L'esecuzione di un comando si effettua con l'opzione **exec** (o **execdir**)

```
find directory options -exec comando '{}' ';'
find directory options -exec comando \{} \;
```

Formati equivalenti

  - Dove
    - Il **comando** viene eseguito nel direttorio
      - In cui la entry è stata rintracciata con **execdir**
      - In cui si esegue la find con **exec**
    - Find sostituisce la stringa '{}' (\{}) con il file corrente dell'elenco
    - La stringa ';' (\;) termina il comando eseguito dalla find

# Esempi: find & actions

```
find . –name “*.c” -print
```

-**print** è l’azione di default

```
find / -type f –print0
find / -type l –print0
```

Visualizza tutti i file regolari o i symbolic link

```
find . –name “*.c” –print –quit
```

Visualizza la prima entry che ha un match e poi esce (**-print** deve essere inserito)

```
find . –name “*.old” -type f –exec rm –f \{} \;
find . –name “*.old” -type f –exec rm –f ‘{}’ ‘;’
```

Cancellazione di file (comandi equivalenti)

# Esempi: find & actions

```
find / -user root –exec cat \{} \;
```

Visualizza tutti i file elencati concatenandoli

```
find / -user root –exec cat ‘{}’ >> file.txt ‘;’
```

Come il precedente ma la concatenazione viene ridiretta nel file file.txt

```
find . –name “*.txt” –exec head –n 2 \{} \;
```

Visualizza le prime due righe di tutti i file elencati

# Esempi: find & actions

```
find /home/usr/ \
  -mindepth 2 -maxdepth 2 \
  -name "*.exe" \
  -type f \
  -exec chmod +x \{} \;
```

Modifica tutti i permessi dei file di estensione "exe" contenuti nel secondo livello gerarchico di direttori a partire da "/home/usr/" aggiungendo il permesso di esecuzione

# Esercizio

- Si riportino i comandi UNIX per effettuare quanto indicato, utilizzando eventuali ridirezioni e pipe
  - Visualizzare quanti file di estensione ".txt" sono presenti nell'albero con radice la working directory
  - Visualizzare quante righe sono presenti in tutti i file di estensione ".txt"
  - Visualizzare il numero di righe totali presenti in tutti i file di estensione ".txt"

# Soluzione

La pipe applica wc (word count) **all'elenco** di tutti i file con estensione .txt. Fornisce il numero di file .txt (e altro)

```
find . -name "*.txt" | wc
```

La exec applica wc (word count) al **contenuto** di tutti i file (\{}) rintracciati. Fornisce numero di righe (e altro) in ogni file .txt

```
find . -name "*.txt" -exec wc \{} \;
```

Come il precedente ma prima concatena i file poi esegue un unico wc (word count) su tale file

```
find . -name "*.txt" -exec cat \{} >> file.txt \; | wc
```