



# Sniffare il traffico di Rete con Python

Un Caso di Studio

Giorgio Zoppi <[zoppi@atsystem.org](mailto:zoppi@atsystem.org)>

# Note su Python

- Linguaggio interpretato a macchina virtuale
  - Scoping statico
  - Passaggio di parametri per valore
  - Macchina Virtuale implementata in : C, C#, Java
  - Ottimo per le ricerche su stringhe

Metafora: Sviluppo rapido, sviluppo meglio.

- <http://www.python.it/>

# Python e lo Sniffing

- Esistono i wrapper python per le comuni librerie C
  - pcap, dnet, nids ...
- Compromesso: performance / tempo / costi
- Moduli, alcuni sono incompleti
  - pypcap/pcappy – pcap per python
  - dpkt – libreria di ricostruzione pacchetti
  - pynids – wrapper per le libnids

# Cosa faremo :)

- Esempio di sniffing con le pcap: contare i pacchetti IP
- Un esempio di ngrep sul payload dei pacchetti
- Un esempio con le libnids usando il pattern matching multiplo nel traffico smtp segnando le mail come spam

# ***Exact set matching problem***

Localizzare occorrenze di più pattern appartenenti ad un insieme  $P = \{P_1, \dots, P_k\}$  in un testo  $T[1, \dots, m]$

Sia  $n = \sum_{i=1}^k |P_i|$

**Exact set matching** può essere risolto con un tempo

$$O(|P_1| + m + \dots + |P_k| + m) = O(n + km)$$

per applicare ogni exact matching di tipo lineare  $k$  volte

## **Algoritmo Aho-Corasick (AC)**

- Classica soluzione di exact set matching
- Lavora in  $O(n + m + z)$ , dove  $z$  è il numero di pattern occorrenze in  $T$

# Keyword Trees

Un **keyword tree**(o **trie**) per un insieme di pattern  $P$  è un albero  $K$  con le seguenti caratteristiche:

- ogni arco è etichettato con un carattere
- due archi uscenti di un nodo hanno etichette differenti

Si definisce l'**etichetta di un nodo**  $v$  come la concatenazione delle etichette sugli archi che compongono il cammino dal nodo radice a  $v$ , e si indica con  $L(v)$ .

- per ogni  $P \in P$  c'è un nodo  $v$  con  $L(v) = P$
- e l'etichetta  $L(v)$  di ogni foglia  $v$  equivale a qualche  $P \in P$

# Keyword Tree: Costruzione


**Costruire** un keyword tree per  $P = \{P_1, \dots, P_k\}$

- Iniziare dal nodo radice
- Inserire ogni pattern  $P_i$ , uno dopo l'altro nel seguente modo:
  - Partire dal nodo radice, seguendo i percorsi etichettati con i caratteri di  $P_i$ . Se il percorso finisce prima di  $P_i$ , continuarlo aggiungendo un nuovo arco e nodo per i rimanenti caratteri di  $P_i$ .
  - Salvare l'identificatore  $i$  di  $P_i$  nell'ultimo nodo del percorso.

Complessità:  $O(|P_1| + \dots + |P_k|) = O(n)$

# *Esempio di un Keyword Tree*

Il keyword tree per  $P = \{he_1, she_2, his_3, hers_4\}$





# ***Keyword Tree: Ricerca***

La **ricerca** di una stringa  $P$ :

Partire dal nodo radice e seguire il cammino etichettato da caratteri di  $P$  fino a quando è possibile.

- Se il cammino si ferma in un nodo in cui è presente un identificatore allora  $P$  è una chiave del dizionario;
- Altrimenti se termina prima di  $P$ , la stringa non appartiene al dizionario.

Complessità:  $O(|P|)$

Un'applicazione banale al pattern matching dovrebbe portare a  $O(nm)$ .

Estenderemo un keyword tree ad un automa per realizzare il matching in tempo lineare

# Automa di Aho-Corasick(1)

**Stati:** nodi del keyword tree (trie).

**Stato iniziale:** 0 = la radice.

L'automa viene definito mediante tre funzioni:

1. la funzione **goto**  $g(q,a)$  da lo stato successivo partendo dallo stato  $q$  facendo il matching del carattere  $a$  (funzione di transizione).

Se un arco  $(q,v)$  è etichettato da  $a$ , allora  $g(q,a) = v$ ;

$g(0,a) = 0$  per ogni  $a$  che non etichetta un arco fuori dalla radice.

. L'automa rimane nello stato iniziale se scandisce caratteri che non corrispondono.

Altrimenti  $g(q,a) = 0$

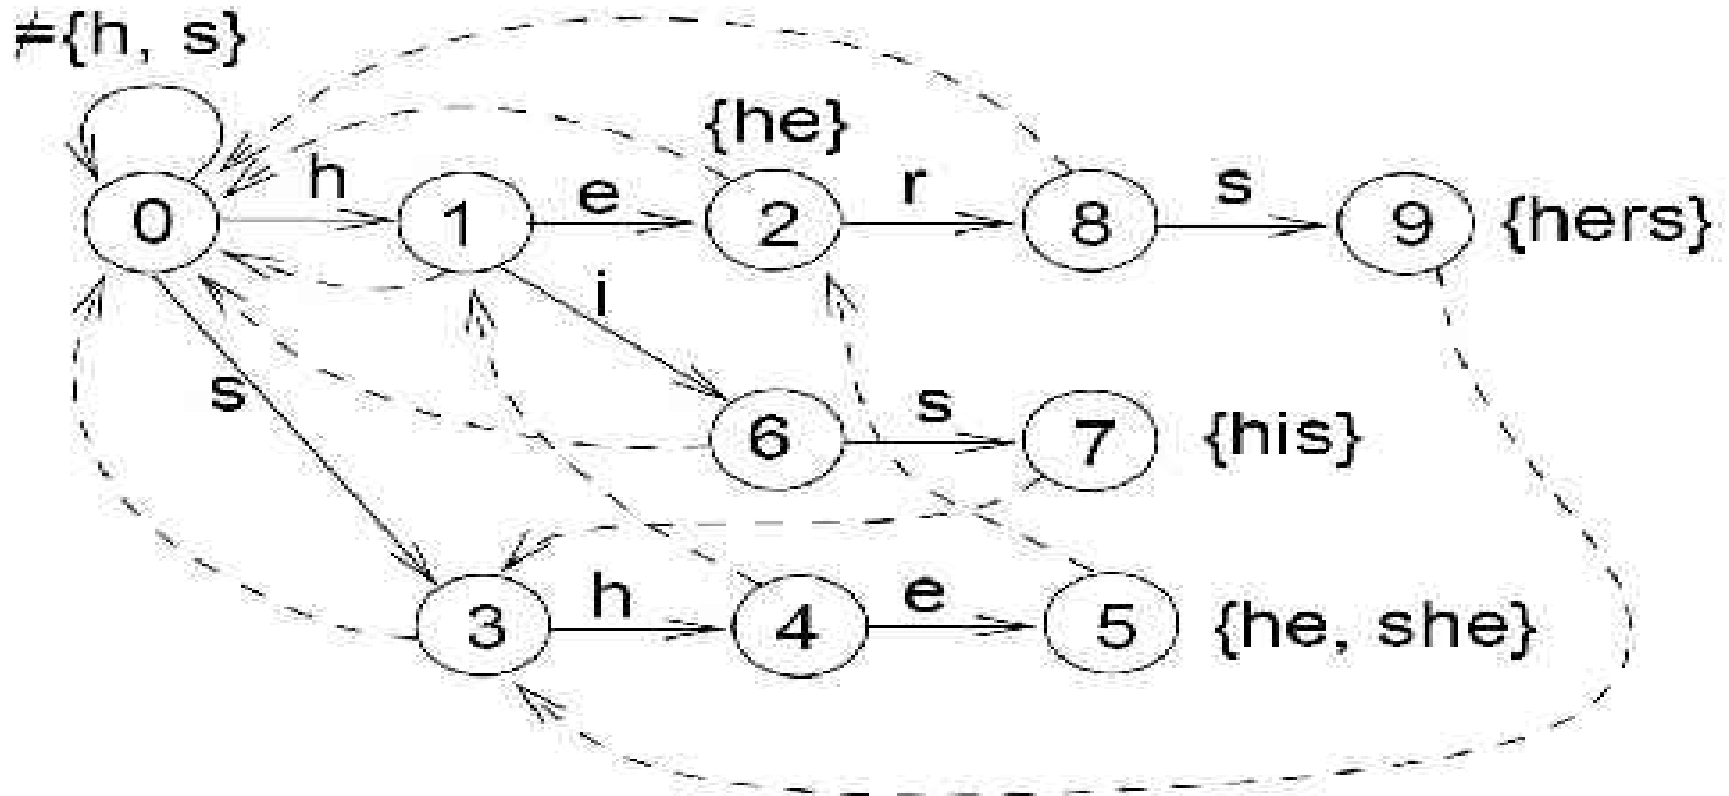
# ***Automa di Aho-Corasick(2)***

2. la **funzione failure**  $f(q)$ , per  $q \neq 0$  dà lo stato in cui mi trovo quando ho mismatch

$f(q)$  è il nodo etichettato dal *più lungo suffisso proprio*  $w$  di  $L(q)$  tale che  $w$  sia prefisso di qualche pattern  $\Rightarrow$  una transizione di fallimento non manca nessuna potenziale occorrenza. Notiamo che  $f(q)$  è sempre definita, poichè  $L(0) = \varepsilon$  è un prefisso di ogni pattern.

3. La **funzione output**  $out(q)$  ci dà l'insieme dei pattern riconosciuti quando entriamo in uno stato  $q$ .

# Esempio di un Automa AC



Le linee tratteggiate sono le transizioni di fallimento

# *Ricerca AC nel testo $T[1..m]$*

```
# Pseudocodice Python.  
  
q = 0 # stato iniziale root  
# range(m+1) funzione che restituisce  
# interi da 1 a m.  
for i in range(1,m+1):  
    while (not Empty(g(q,T[i]))):  
        q = f(q); # segui un fallimento  
    q = g(q,T[i]);# segui un goto  
    if (not Empty(out(q))):  
        print i, out(q)
```

# Primo esempio con le pycap

# **libnids** – riassembla gli stream IP

**NIDS “E” box (event generation box)**  
**Userland TCP/IP stack**  
**Rimarca lo stack IP di Linux 2.0.36 IP**  
**internamente**  
**Si basa su libnet e libpcap**  
**IP fragment reassembly**

**Userland**



The diagram consists of a large white rectangle labeled 'Userland' at the top left. Inside the bottom right corner of this rectangle is a smaller light blue rectangle labeled 'Kernel'. Within the bottom right corner of the 'Kernel' rectangle is an orange rectangle labeled 'IP stack'. All rectangles have black outlines.

**Kernel**

**IP stack**



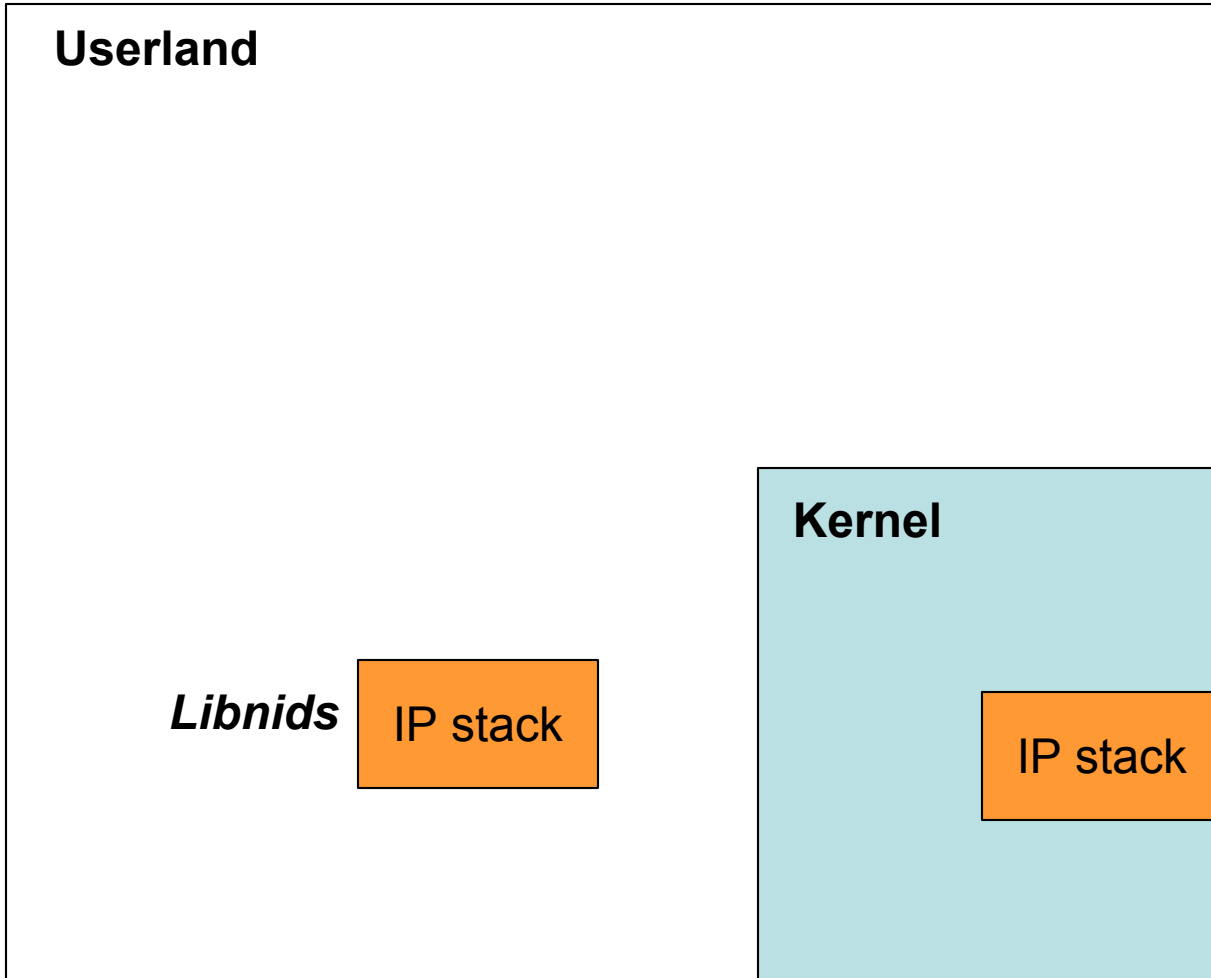
**Userland**

***Libnids***

IP stack

**Kernel**


IP stack



# Fasi di Libnids

- Inizializzazione
  - `nids_init()`
- Registrazione callback
  - `nids_register_tcp()`
  - `nids_register_ip()`
  - `nids_register_udp()`
- Esecuzione
  - `nids_run()`
- Reazione
  - `nids_kill_tcp()`

# nids\_run()



## TCP callback

TCP stream object:

- TCP state
- client data
- server data
- source IP, port
- dest IP, port
- seq, ack, etc ...

## UDP callback

UDP packet:

- source IP, port
- dest IP, port
- UDP payload

## IP callback

IP packet

- struct IP packet

# Automa di libnids

- **NIDS\_JUST\_ESTABLISHED**
  - L'handshake TCP ha avuto luogo
  - Devi impostare `stream->{client,server}.collect=1` per ottenere i payload raccolti
- **NIDS\_DATA**
  - Ci sono dati e la connessione è stata stabilita
- **NIDS\_RESET, NIDS\_CLOSE, NIDS\_TIMED\_OUT**
  - La connessione TCP è stata persa, resettata o si è verificato un timeout

# Introduzione a pynids

- Interfaccia event driven (`nids_run()`, `nids_next()`)
  - TCP stream reassembly
  - espone lo stato TCP
  - Crea un oggetto TCP
- Mantiene gli indirizzi, i dati, ecc
  - Riassembly TCP

# Passi di base per Libnids

- **Inizializzazione**
  - `nids_init()`
- **Stabiliamo un parametro**
  - `nids.param("attribute", value)`
- **Registriamo le callback**
  - `nids.register_tcp(handleTcp)`
  - `def handleTcp(tcp): ...`
- **Esecuzione!**
  - `nids_run()`
  - `while 1: nids_next()`

# Elaborazione locale in Pynids

- Nota: Ho registrato le callback.
- Durante il transito dei pacchetti cosa succede?
- TCP
  - Posso creare nuovo stato interno o riusare
  - Append data
  - L'elaborazione secondo lo stato che vede la callback
- UDP o IP?
  - L'elaborazione (stateless) avviene nella callback

# Esempio di codice (Python)

```
import nids
<handleTcpStream>

def main():
    nids.param("scan_num_hosts", 0)
    if not nids.init():
        print "error -", nids.errbuf()
        sys.exit(1)
    nids.register_tcp(handleTcpStream)
    try:        nids.run()    # loop forever
    except KeyboardInterrupt:
        sys.exit(1)
```



# Esempio di codice Python

```
def handleTcpStream(tcp):
    if tcp.nids_state == nids.NIDS_JUST_EST:
        if dport in (80, 8000, 8080):
            tcp.client.collect = 1
            tcp.server.collect = 1
        elif tcp.nids_state == nids.NIDS_DATA:
            tcp.discard(0)
        elif tcp.nids_state in end_states:
            print "addr:", tcp.addr
            # may be binary
            print "To server:", tcp.server.data
            print "To client:", tcp.client.data
```

# Esempio di codice in C

```
int main(int argv, char *argv[])
{
    if (nids_init() == 0)
        err(1, "error, %s", nids_errbuf);
    nids_register_tcp(handleTcp);
    nids_run();
    exit(0);
}
```

# Esempio di codice in C

```
int handleTcp(struct tcp_stream *tcp)
{
    switch (tcp->nids_state) {
        case 'NIDS_JUST_EST':
            if ((tcp->addr.dest == 80) ||
                (tcp->addr.dest == 8000) ||
                (tcp->addr.dest == 8080) {
                tcp.server.collect = 1;
                tcp.client.collect = 1;
            }
            break;
        case 'NIDS_DATA':
            nids_discard(tcp, 0);
            break;
        case 'NIDS_CLOSE':
        case 'NIDS_RESET':
        case 'NIDS_TIMED_OUT':
            printf("( (%s, %d), (%s, %d))\n", inet_ntoa(tcp->saddr), tcp.srce,
                inet_ntoa(tcp->daddr), tcp.dest);
            printf("%s\n", tcp->server.data);
            printf("%s\n", tcp->client.data);
            break;
    }
}
```

**Quasi le stesse LoC prima di manipolare le stringhe**

# VersionDetect

- Semplice programma Python scritto da Nazario
- Rileva la versione di diversi protocolli
  - Supporto per : SSH (client, server), WWW (client, server), e SMTP
- Motivazione: raccogliere dati per fare stack fingerprinting

63.236.16.161

SymbianOS 6048 (on Nokia 7650?)

www

80/tcp

63.236.16.161: 80: Microsoft-IIS/6.0

# Output di VersionDetect

```
192.168.1.7: 22: SSH-2.0-OpenSSH_3.5
192.168.1.101:http: Mozilla/5.0 (X11; U; OpenBSD i386; en-
    US; rv:1.5a) Gecko/20031030 Mozilla Firebird/0.6.1

168.75.65.85: 80: Microsoft-IIS/5.0
165.1.76.60: 80: Netscape-Enterprise/3.6 SP2
168.75.65.69: 80: Microsoft-IIS/5.0
168.75.65.87: 80: Microsoft-IIS/5.0
69.28.159.7: 80: ZEDO 3G
198.65.148.234: 80: Apache/1.3.29 (Unix) PHP/4.3.3
216.150.209.231: 80: Apache/1.3.31 (Unix)
212.187.153.30: 80: Apache/1.3.31 (Unix)
212.187.153.37: 80: Apache/1.3.31 (Unix)
212.187.153.32: 80: thttpd/2.25b 29dec2003
64.209.232.207: 80: Apache/1.3.27 (Unix)
    mod_perl/1.27
216.239.39.99: 80: CAFE/1.0
```

# Controllare dati con pynids

- Nota: `tcp.{server, client}.data` sono solo stringhe
- Allora: funzionerà ogni manipolazione di stringhe

- Ricerca

```
if "HTTP/1.0" in tcp.client.data:
```

- Ricerca mediante espressioni regolari

```
if re.search("HTTP/1.[10]", tcp.client.data):
```

- Sostituzione di parti di stringhe

```
string.replace(req, "GET HTTP/1.0", "", 1)
```

# Risorse

- <http://www.tcpdump.org/>
- <http://www.packetfactory.net/projects/libnids/>
- <http://monkey.org/~provos/libevent/>
- <http://monkey.org/~dugsong/{dpkt, pycap}>
- <http://oss.coresecurity.com/projects/pcapy.html>
- <http://monkey.org/~jose/software/flowgrep/>
- <http://pilcrow.madison.wi.us/pynids/>

# Thanks

Antonio Cisternino <[cisterni@di.unipi.it](mailto:cisterni@di.unipi.it)>



Thanks