

# Metodi e tecniche per la rilevazione e il contrasto di botnet in reti universitarie

Andrea Balboni

andreabalboni@gmail.com



**7° Borsisti Day**

20/01/2016

Roma – Consortium GARR



## Studio di tecniche e metodi innovativi per l'individuazione e il contrasto di botnet e di server di Comando e Controllo

- Elementi originali:
  - Acquisizione e integrazione dati da **molteplici sorgenti eterogenee**
  - Focalizzazione sulla correlazione e analisi dei **log DNS**

# Fasi del progetto

**1. Acquisizione**

**2. Analisi**

**3. Risultati**

## Fonti eterogenee

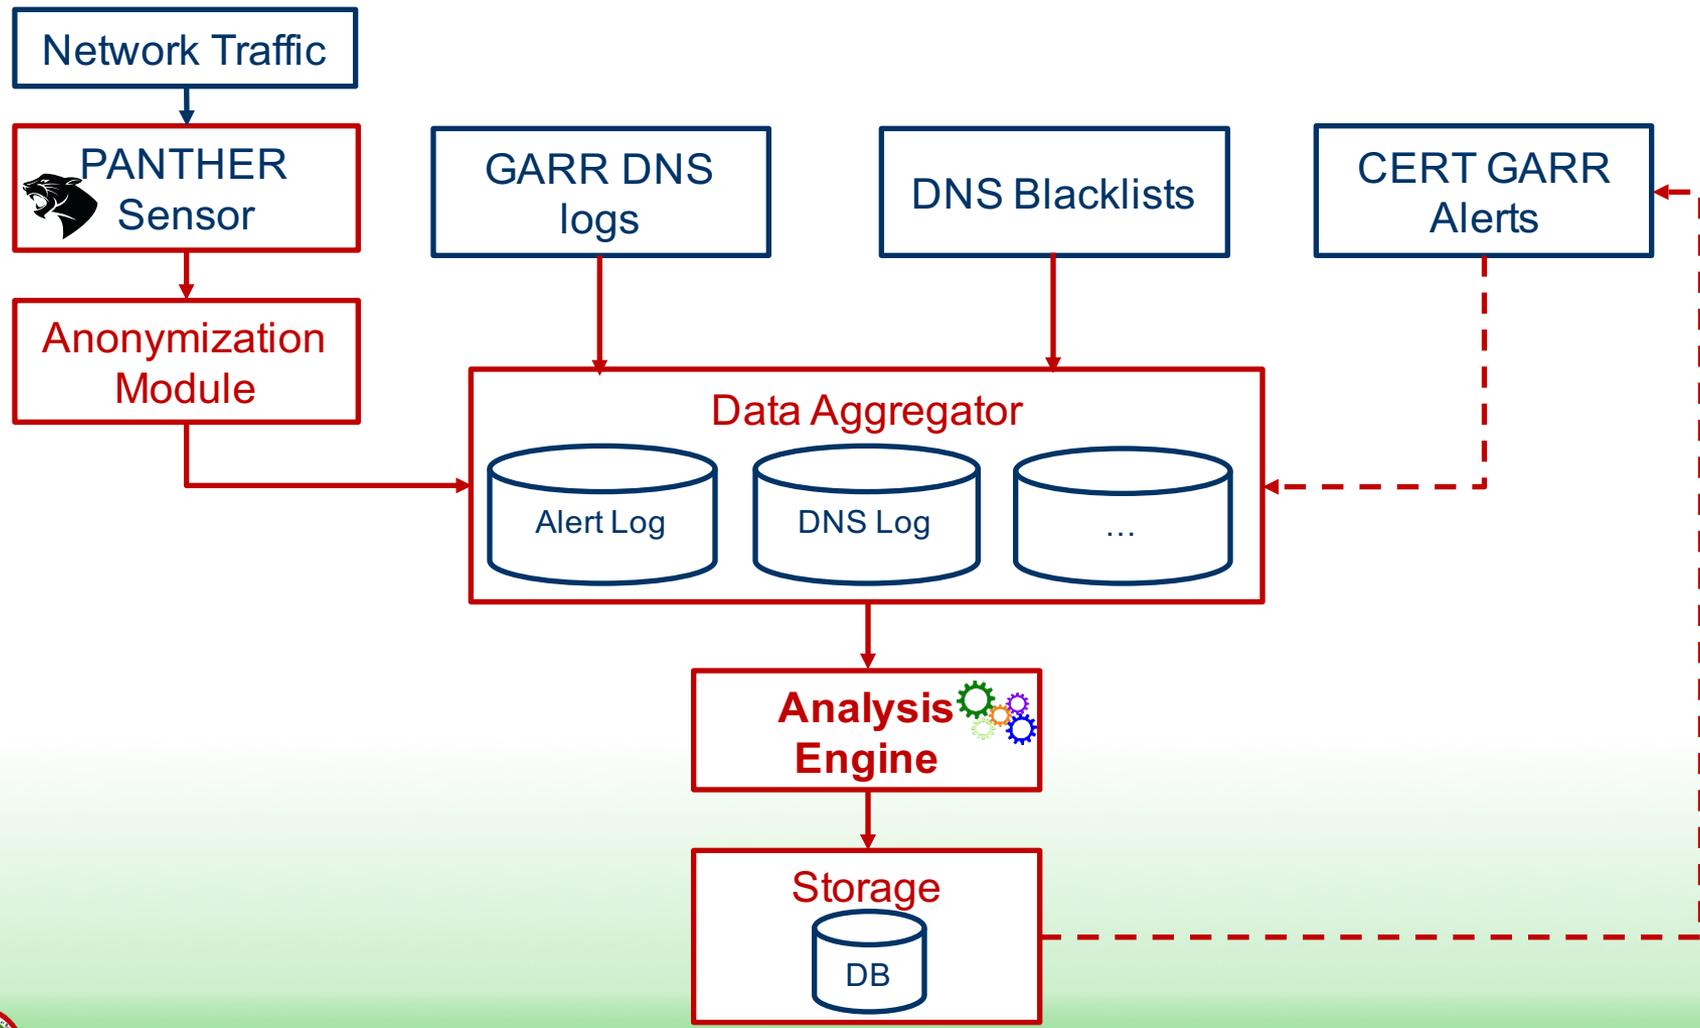
- log di analizzatori di traffico di rete
- log di un server DNS GARR
- blacklist DNS

→ necessario individuare un **formato univoco**

**Dati sensibili** → necessario adottare tecniche di  
anonimizzazione **privacy preserving**

**Volumi elevati di dati in costante crescita** →  
necessario progettare un **sistema scalabile** per storage e  
indexing

# Acquisizione dati: *Architettura*



# Anonimizzazione dei dati sensibili: *soluzione adottata*

## Utilizzo di algoritmi di cifratura AES

- chiave conosciuta solo dall'amministratore di rete
- mancato utilizzo di initialization vector garantisce che a ogni valore in chiaro corrisponda sempre lo stesso valore cifrato



# Aggregazione dati da sorgenti eterogenee: sottosistemi

**Data Aggregator → 2 sottosistemi**

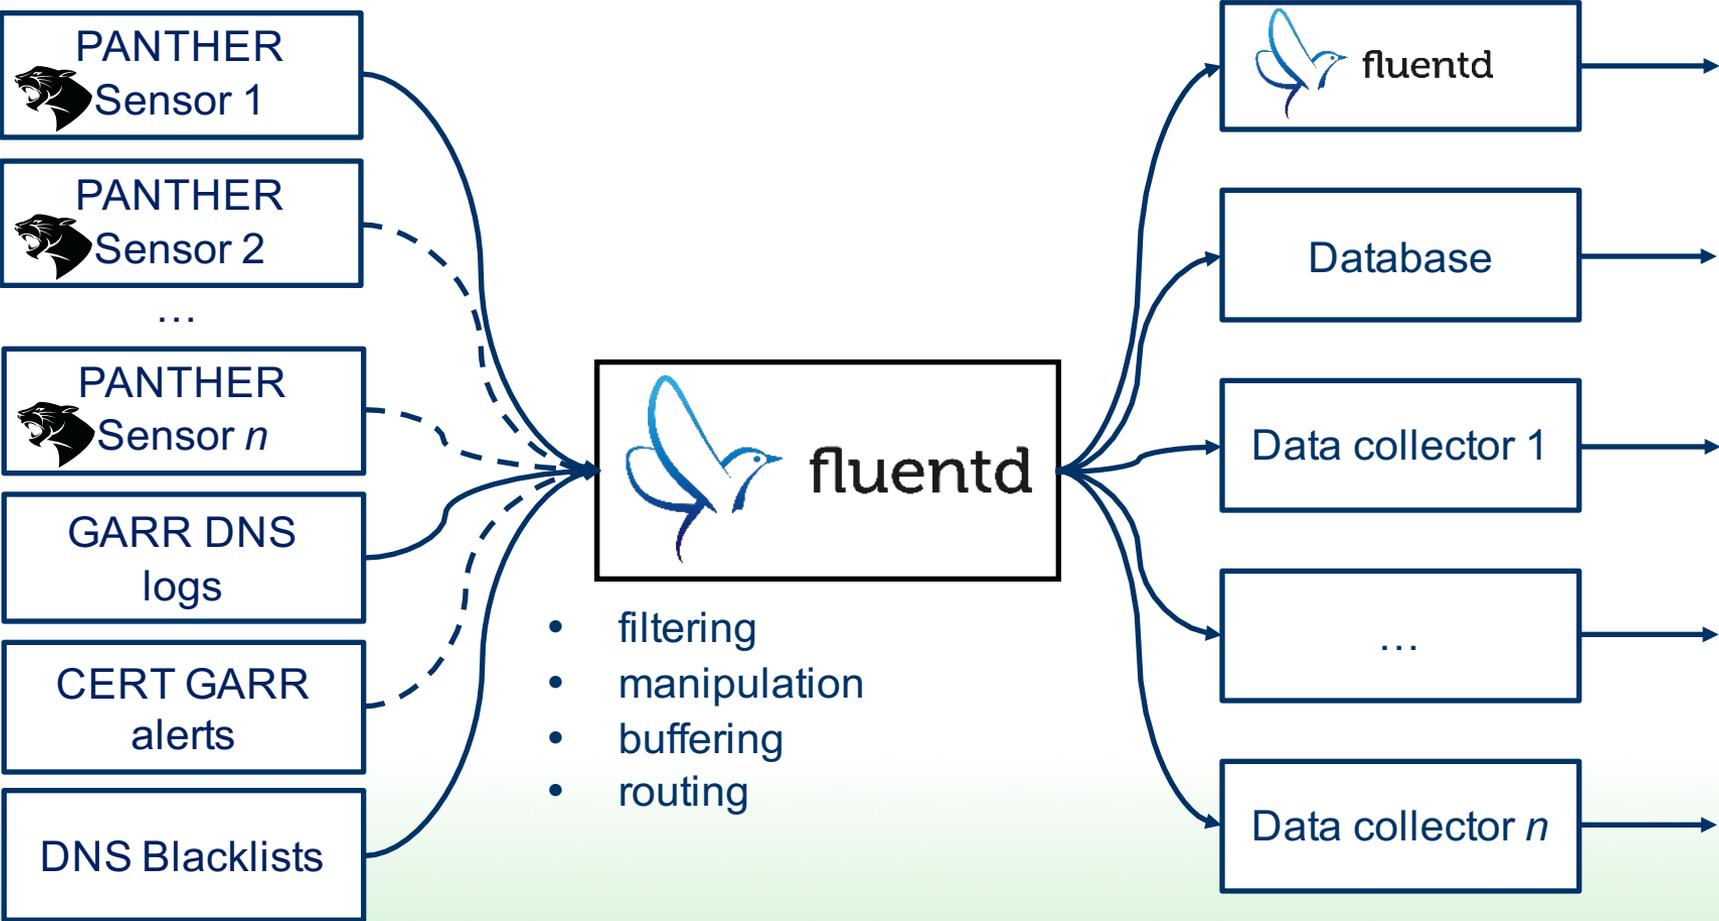
## 1. Data collection e routing

- parsing
- manipolazioni
- conversioni di formato → formato univoco JSON
- inoltro a diverse destinazioni

## 2. Storage e indicizzazione

- memorizzazione
- indicizzazione multipla
- ricerche e filtri

# Data collection: schema



# Storage e indicizzazione: elasticsearch



- Storage distribuito
- Funzionalità avanzate di indicizzazione
  - Distribuzione indici su più nodi di elaborazione e storage
- Motore di ricerca
- Filtri avanzati
- Aggregazione

**1. Acquisizione**

**2. Analisi**

**3. Risultati**

# Analisi focalizzata sui log DNS

- Le moderne botnet coinvolgono il DNS in diversi ambiti:
  - **Comunicazioni** tra bot e server di comando e controllo (C&C)
  - Attività di perlustrazione del bot-master per verificare l'eventuale blacklisting DNS dei **nomi di dominio associati ai bot o ai server di controllo**
- Possibilità di rilevare botnet **indipendentemente dal protocollo** che utilizzano (HTTP, IRC, ...)

**Domain Generation Algorithms (DGA)**  $\Rightarrow$  per diminuire le probabilità di essere individuati, i bot contattano i server C&C e/o i peer attraverso nomi di dominio auto-generati. Es.,

- `razzrwsbzum.org`
- `jbfygzlczjak.info`

## Obiettivo della ricerca

Classificazione automatica dei nomi di dominio  $\Rightarrow$   
{*sospetti, non sospetti*}

- Classificatore realizzato mediante euristiche sulle label dei nomi di dominio
  - lunghezza
  - rapporto vocali/consonanti inconsueto
  - numerosità vocali/consonanti inconsueta
  - assenza di parole di senso compiuto
- Classificatore implementato come plugin custom per fluentd
  - dati analizzati e annotati prima di essere memorizzati e indicizzati

# Integrazione con blacklist DNS

- Ogni record DNS viene analizzato per verificare se il nome di dominio richiesto è presente in blacklist
- Blacklist configurabili e aggiornate quotidianamente
  - Malware Domains: <http://www.malwaredomains.com/>
  - AAMS:  
[http://www.servizi.garr.it/aams/aams\\_block\\_domain.txt](http://www.servizi.garr.it/aams/aams_block_domain.txt)

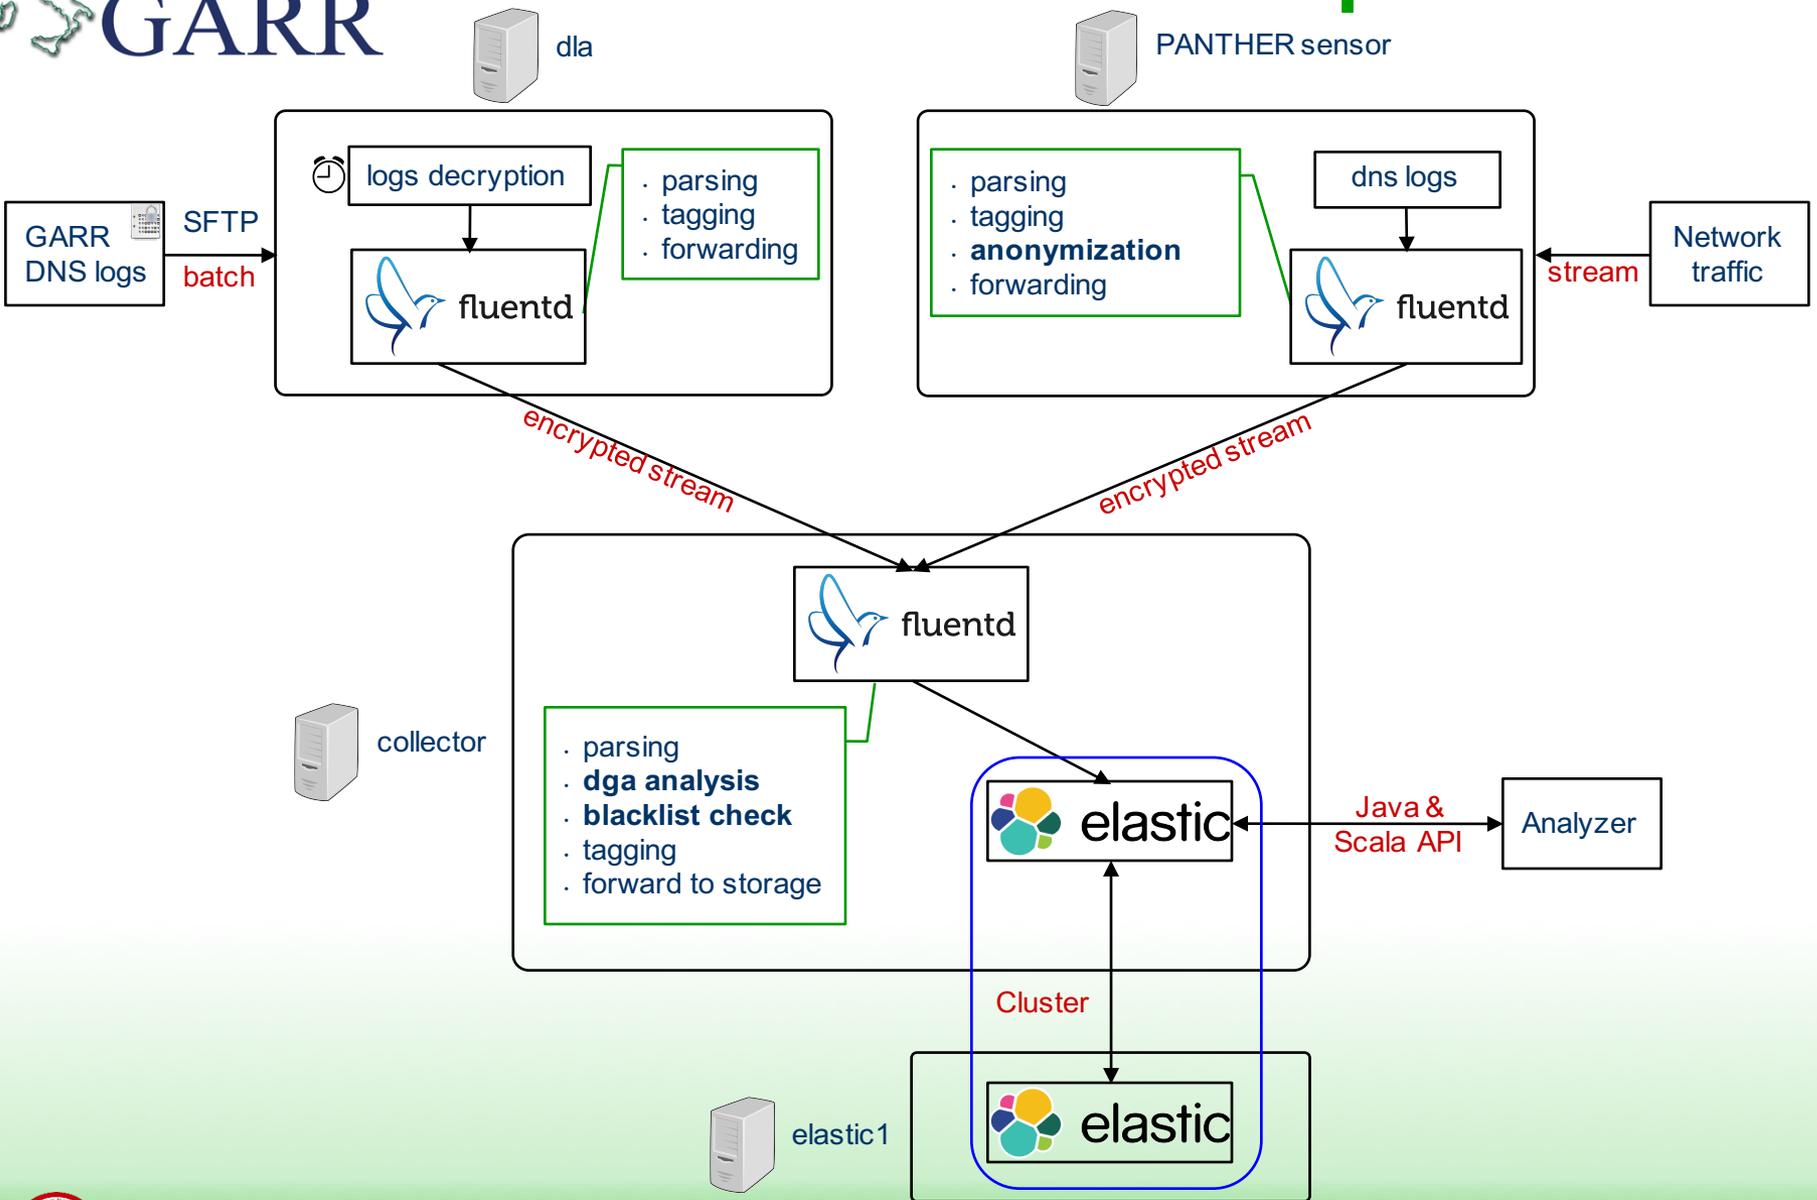
# Fasi del progetto

**1. Acquisizione**

**2. Analisi**

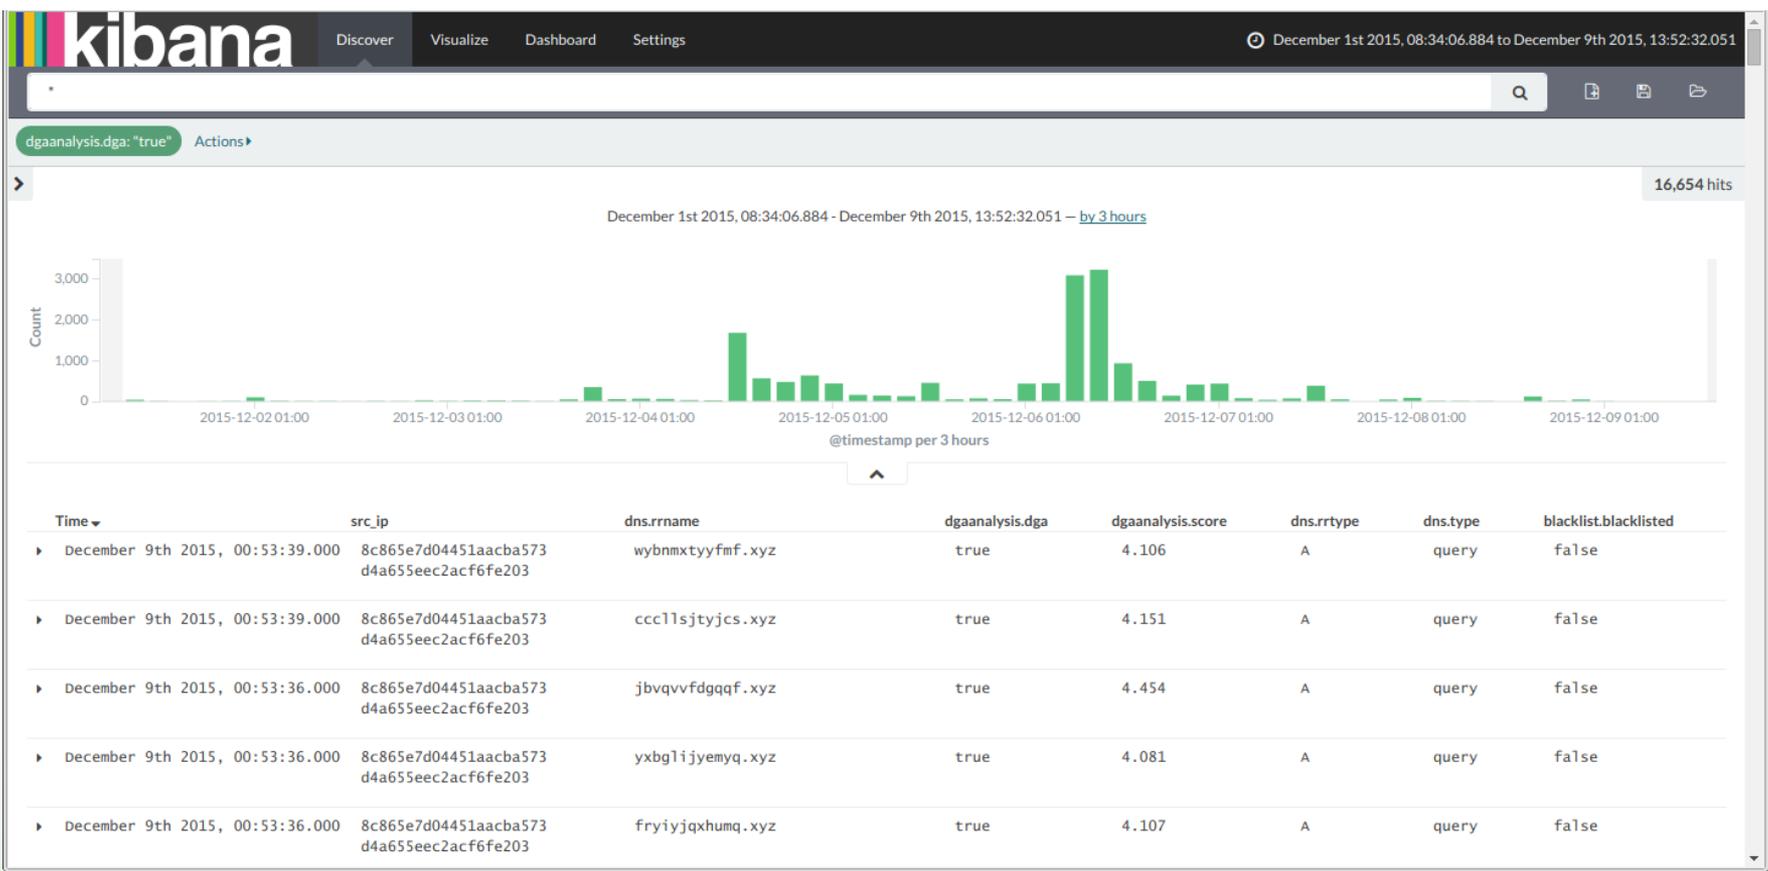
**3. Risultati**

# Prototipo realizzato



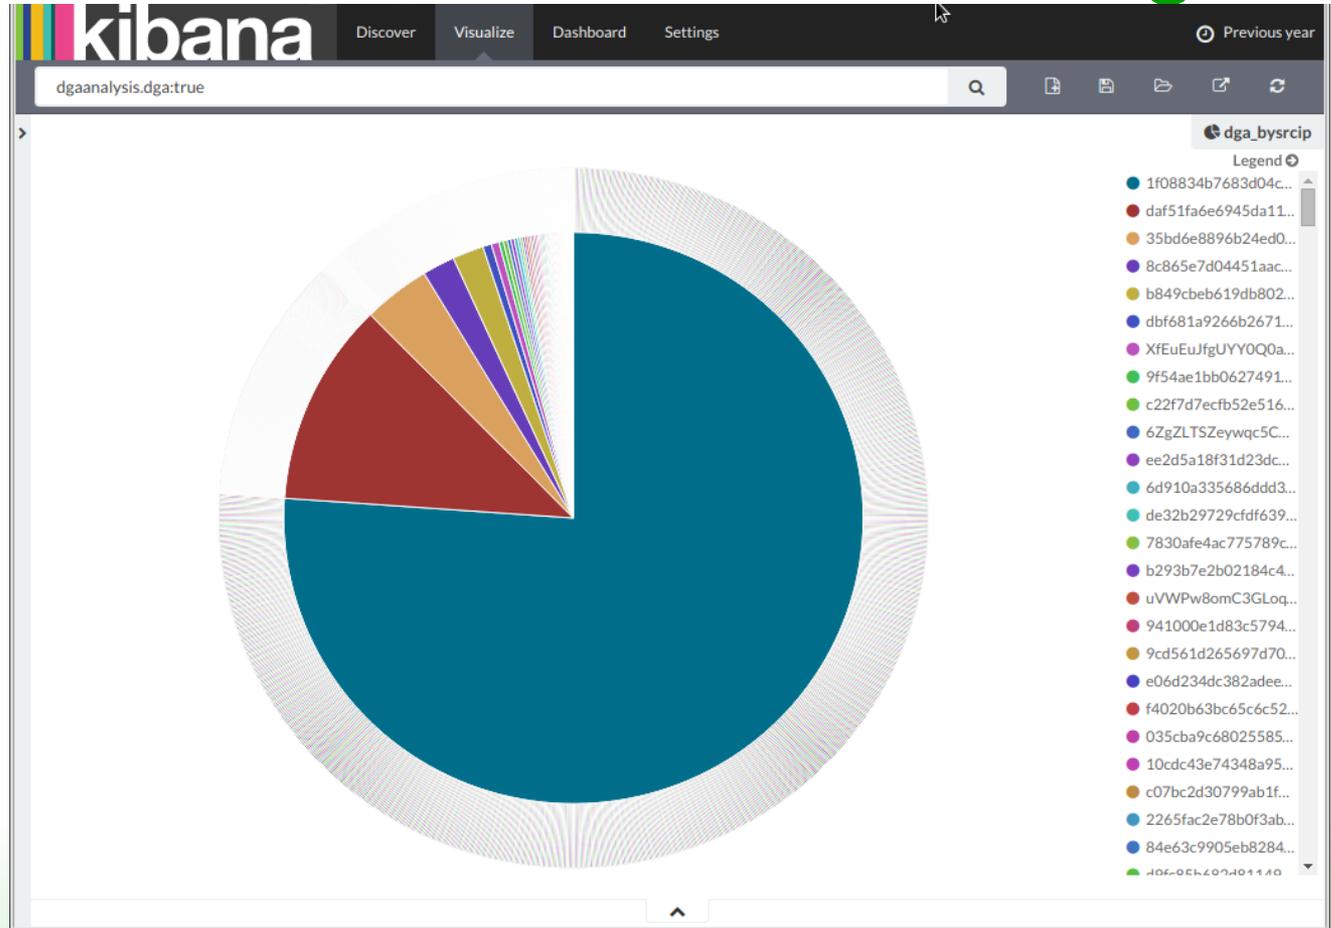
- **6.6 miliardi** di query DNS analizzate e indicizzate
  - circa 1.3 TB di dati
- Segnalati numerosi DGA in 2 mesi di traffico:
  - GARR: 31.480 query per **21.911 DGA**
  - UNIMORE: 12.510 query per **10.500 DGA**
- Falsi positivi: 2.9% con pre-filtering
- Tempi di estrazione dati:
  - 30 secondi - 3 minuti

# Interfaccia di consultazione



# Distribuzione richieste DGA per IP sorgente

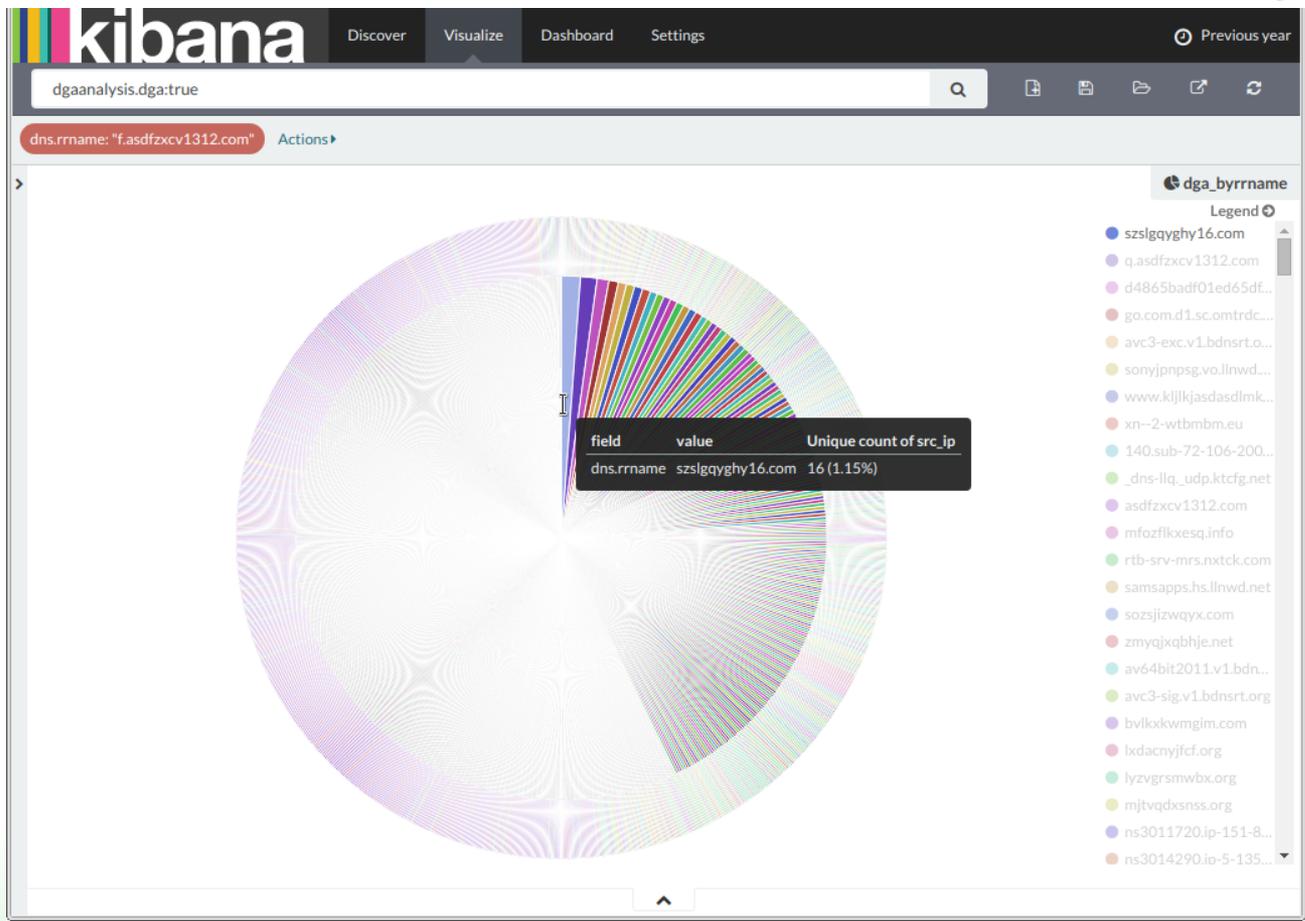
Name server configurati per ricorsione effettuano la maggior parte di richieste per DGA



# Distribuzione richieste per ogni DGA

Nomi DGA tipicamente richiesti una sola volta e da un singolo indirizzo sorgente

Richieste multiple possono indicare botnet attiva



# Obiettivi del secondo anno

1. Individuazione di algoritmi e tecniche per **migliorare il riconoscimento di nomi DGA**
  - Riduzione falsi positivi
  - Integrazione dei nomi di **dominio internazionalizzati IDN**
2. **Anomaly detection** basata sui pattern di richieste di host potenzialmente infetti con quelli di host non infetti e sui tempi di inter-arrivo delle richieste a DNS per nomi di dominio sospetti
3. Miglioramento della **scalabilità** della piattaforma per avere risultati delle analisi in tempo reale

*Si garantisce l'aspetto sperimentale della ricerca mediante prototipi. Qualche problema nell'accesso a set di dati reali.*

- S. Yadav, A. K. K. Reddy, A. L. N. Reddy, and S. Ranjan, “Detecting algorithmically generated malicious domain names,” presented at the the 10th annual conference, New York, New York, USA, 2010, pp. 48–61.
- A. Reddy, “Detecting Networks Employing Algorithmically Generated Domain Names,” 2010.
- Bilge, Leyla, Engin Kirda, Christopher Kruegel, and Marco Balduzzi. "EXPOSURE: Finding Malicious Domains Using Passive DNS Analysis." In NDSS. 2011.
- S. Yadav, A. K. K. Reddy, A. L. N. Reddy, and S. Ranjan, “Detecting algorithmically generated domain-flux attacks with DNS traffic analysis,” IEEE/ACM Transactions on Networking (TON, vol. 20, no. 5, Oct. 2012.
- Z. Wei-wei and G. Qian, “Detecting Machine Generated Domain Names Based on Morpheme Features,” 2013.
- P. Barthakur, M. Dahal, and M. K. Ghose, “An Efficient Machine Learning Based Classification Scheme for Detecting Distributed Command & Control Traffic of P2P Botnets,” International Journal of Modern ..., 2013.