

Solução de detecção de intrusão usando técnicas de Big Data para a análise de logs com o uso de Software Livre

William Rennan de Castro Vidal

Roteiro

- * Motivação e Objetivos
- * Conceitos Básicos
- * Proposta e Implementação
- * Avaliação Experimental
- * Conclusão e Trabalhos Futuros

Roteiro

- * **Motivação e Objetivos**
- * Conceitos Básicos
- * Proposta e Implementação
- * Avaliação Experimental
- * Conclusão e Trabalhos Futuros

Motivação

- * Segurança em redes de computadores
 - * Sistema de detecção/prevenção de intrusão
 - * Há outras técnicas: Firewall, DMZ, etc.
- * Problemas IDS/IPS
 - * Quantidade de logs
 - * Falta de padronização

Objetivos

- * Implementar um IDS
 - * Por meio de técnicas de Big Data
 - * Baseado, exclusivamente, em Software Livre

- * Avaliar o desempenho da solução proposta a partir de logs de autenticação reais do PoP-RS

Roteiro

- * Motivação e Objetivos
- * **Conceitos Básicos**
- * Proposta e Implementação
- * Avaliação Experimental
- * Conclusão e Trabalhos Futuros

Conceitos Básicos

- * Segurança da Informação
 - * Base: Confidencialidade, Autenticidade e Disponibilidade
 - * Usando técnicas de detecção, e prevenção de intrusão
- * Detecção de Intrusão
 - * Detecção Estatística de Anomalia
 - * Detecção Baseada em Regras
- * Necessidade: Analisar logs em busca de padrões de atividade maliciosas
- * Problema: Tamanho e variedade dos logs

Conceitos Básicos


- * Grande Volume de dados (Big Data)
 - * Objetivo: Extrair de quantidade massivas de dados informações relevantes
 - * Fases: Geração, aquisição, armazenamento e análise (Analytics)
- * Características:
 - * Volume, velocidade, variedade e valor (4Vs)
 - * Visualização

SCHROECK, M. et al. Analytics: The real world use of big data. ibm institute for business value—executive report. IBM Institute for Business Value, 2012.
DIJCKS, J. P. Oracle: Big data for the enterprise. Oracle White Paper, 2012.
NIST BIG DATA WORKING GROUP (NBD-WG). Big data: The next frontier for innovation, competition, and productivity. 2011. Disponível em:
<https://bigdatawg.nist.gov/MGI_big_data_full_report.pdf>

Roteiro

- * Motivação e Objetivos
- * Conceitos Básicos
- * **Proposta e Implementação**
- * Avaliação Experimental
- * Conclusão e Trabalhos Futuros


Arquitetura Proposta do Sistema




HU, H. et al. Toward scalable systems for big data analytics: A technology tutorial. Access, IEEE, IEEE, v. 2, p. 652–687, 2014.
KRUEGEL, C.; VALEUR, F.; VIGNA, G. Intrusion detection and correlation: challenges and solutions.
[S.l.]: Springer Science & Business Media, 2005. v. 14.

Geração

- * Heterogêneos
- * Não Estruturado



Aquisição e Normalização



* Facility

Marca Temporal

2015-07-17T12:03:51-03:00

Origem

tcc-server

Serviço
com PID

sshd[58807]

Mensagem

Accepted publickey for agulha from 10.10.10.10 port 45162 ssh2



syslog-ng

Filtro



- * Extração de informações relevantes

Regra:


```
"Accepted %{WORD:auth_method} for %{USER:username} from %{IP:src_ip} port %{INT:src_port} ssh2"
```

```
Accepted publickey for agulha from 10.10.10.10 port 45162 ssh2
```



logstash

Filtro



```
input {
  file {
    path => "/home/william/auth.log"
    type => "logAuth"
    start_position => "beginning"
  }
}

filter {
  grok {
    match => {"message" => "Accepted %{WORD:auth_method} for
              %{USER:username} from %{IP:src_ip} port %{INT:src_port} ssh2" }
    add_field => {
      "ssh_type_conection" => "ssh_sucesessfull_login" }
  }
  ...
}

output {
  elasticsearch {
    protocol => http
    host => "localhost" }
}
```



logstash

Armazenamento




```
{
  "message" => "2015-07-17T12:03:51-03:00 tcc-server sshd[58807]: Accepted publickey for
agulha from 10.10.10.10. port 45162 ssh2",
  "auth_method" => "publickey",
  "username" => "agulha",
  "src_ip" => "10.10.10.10",
  "src_port" => "45162",
  "timestamp" => "17/Jul/2015 12:03:51 -0300",
  "target" => "tcc-server",
  "service" => "sshd",
  "pid" => "58807",
}
```



elasticsearch.


Análise



Correlação: MapReduce




Visualização



Dificuldades

- * Programação com o modelo MapReduce
 - * Complexidade em mapear a solução em duas primitivas
- * Solução possível:
 - * Utilização do Pig
 - * Linguagem Script
 - * Abstração ao MapReduce



Dificuldade Adicional

- * Existem pacotes Pig para carregar informações específicas
 - * Log do Servidor Apache
- * Não é exaustivo
 - * Expressão Regular para caso específico
 - * Dificuldade de escrita

```
REGISTER /usr/lib/pig/pig-0.15.0/lib/piggybank.jar;
logs = LOAD '/home/hduser/logsAuth/auth*.log' USING org.apache.pig.piggybank.storage.
    MyRegexLoader ('^(\\S+)\\s+(\\S+)\\s+(\\w+)\\s+\\s+([\\S+\\s+]*\\$') AS (timestamp:
    chararray, host:chararray, program:chararray, message:chararray);
searchData = FILTER logs BY message MATCHES '.*agulha.*';
STORE searchData INTO '$myOutput/' USING PigStorage('');
```

Novo Problema


- * Bug na utilização do Pig

Elasticsearch for Apache Hadoop 2.1.1


Bug fixes

- Load error from elasticsearch using Pig and the elasticsearch connector #499
<https://www.elastic.co/downloads/past-releases/elasticsearch-apache-hadoop-2-1-1>

- * Consequência: Perdida a ligação com o Elasticsearch



Implementação Final



- * Inspeção Visual
- * Análise manual

Roteiro

- * Motivação e Objetivos
- * Conceitos Básicos
- * Proposta e Implementação
- * **Avaliação Experimental**
- * Conclusão e Trabalhos Futuros

Metodologia

- * Uso de logs reais do PoP-RS
- * Comparação: desempenho bash x Pig Latin
 - * Critério: tempo de execução
 - * Diferentes volumes de dados
- * Validação estatística: Média e Desvio Padrão

Plataforma Experimental


- * Hardware
 - * HP ProLiant DL380
 - * Servidor Virtualizado
 - * 4 CPUs
 - * 4GB RAM
 - * 150GB Disco
 - * Hypervisor: XenServer 6.5
- * Software
 - * Ubuntu 12.04.5 LTS
 - * Hadoop 2.7.0
 - * Pig 0.15.0
 - * *demais serviços (Syslog-NG, Logstash, ElasticSearch, etc.)

Cenários de Teste

- * Cenário I
 - * Busca em campo específico
 - * Busca em campo de strings
- * Cenário II
 - * Busca em 2 e 3 campos
- * Cenário III
 - * Busca com ordenação


Cenário I: Busca em um campo específico

* Busca por hospedeiro




Cenário I: Busca em um campo com strings

* Busca por usuário




Cenário II: Busca em dois campos

* Busca por data e usuário




Cenário II: Busca em três campos

* Busca por data, hospedeiro e usuário



Cenário III: Busca com ordenação

* Ordenação e busca por data e usuário



Roteiro

- * Motivação e Objetivos
- * Conceitos Básicos
- * Proposta e Implementação
- * Avaliação Experimental
- * **Conclusão e Trabalhos Futuros**

Conclusão

- * Estudo de viabilidade
 - * Funciona, implementado e testado
 - * Integrada ao ambiente de produção do PoP-RS
 - * Análise manual por inspeção visual
- * Resultados
 - * Baixo desempenho se comparado com grep no bash
 - * Camadas de Software (Hadoop+Pig)
 - * Volume de dados talvez seja pequeno
 - * Não foi usado em ambiente distribuído

Conclusão

- * Contribuição

- * Protótipo funcional para análise de logs para o PoP-RS
- * Estudo de ferramentas em Software Livre para Big Data
 - * Logstash, ElasticSearch, Fluentd, Kibana, Hadoop, Flume, Pig,...

Trabalhos Futuros

- * Implementar em um ambiente distribuído
- * Utilizar Apache Storm e Apache Spark para análise em tempo real
- * Implementar Regras e Filtros mais complexos
- * Analisar desempenho para volume de dados maiores

Agradecimento



Contatos

- * LinkedIn: <https://www.linkedin.com/in/william-vidal-317126105>
- * E-mail: wrcvidal@gmail.com
- * TCC: <http://www.lume.ufrgs.br/handle/10183/139086>

Obrigado!

- * Perguntas?
- * Demonstração?

