

ELK

镜像站日志可视化分析

主讲人：潘富

南阳理工学院镜像站

2024-08-17 南京大学 开源软件论坛



目录

- 背景介绍
- 技术选型
- 日志收集与分析
- 日志可视化展示
- 后续工作



背景介绍

- 日志在镜像站中的重要性
- 在成千上万条数据中检索过于繁琐
- 被恶意刷流后不方便查看涉事IP的行为
- 镜像站总体的数据分析



技术选型

- Elasticsearch（基于Lucene的搜索服务器）
- Kibana（ELK栈中的可视化工具）
- Filebeat（日志数据收集器）
- Grafana（数据展示）



日志收集与分析

- 安装并配置filebeat
- 启用 nginx 模块 `filebeat modules enable nginx`
- 日志整体流向为: `Filebeat -> Elasticsearch -> Grafana`
- 使用 Kibana 对来自 Filebeat 的数据流进行处理

日志收集与分析

- NYIST 所采用的日志格式
- `'$remote_addr - $remote_user [$time_local] "$request" $status $body_bytes_sent "$sent_http_content_type" "$http_referer" "$http_user_agent" - $scheme "$host" - "$request_time" "$upstream_response_time" "$http_x_forwarded_for"'`
- `114.5.1.4 - - [17/Aug/2024:14:30:57 +0800] "GET /CTAN/fonts/greek/cbfonts/fonts/tfm/cbgreek/glto0800.tfm HTTP/1.1" 200 2032 "application/octet-stream" "-" "Mozilla/5.0 (Macintosh; Intel Mac OS X 11_3_0) AppleWebKit/537.36 (KHTML, like Gecko) Brave Chrome/89.0.4389.114 Safari/537.36" - https "mirror.nyist.edu.cn" - "0.053" "0.053" "-"`

日志收集与分析

- Kibana对日志进行GORK
- `(%{NGINX_HOST})"?(?:%{NGINX_ADDRESS_LIST:nginx.access.remote_ip_list}|%{NOTSPACE:source.address}) - (-|{%DATA:user.name}) \[%{HTTPDATE:nginx.access.time}\]
"%{DATA:nginx.access.info}" {%NUMBER:http.response.status_code:long}
{%NUMBER:http.response.body.bytes:long} "(-|{%DATA:http.content.type})" "(-
|{%DATA:http.request.referrer})" "(-|{%DATA:user_agent.original})" - (-
|{%DATA:http.scheme}) "(-|{%DATA:http.url.domain})" - "(-
|{%NUMBER:http.request.time:float})" "(-|{%NUMBER:http.upstream_response.time:float})" "(-
|{%NOTSPACE:http.xff})`
- `{`
- `"NGINX_HOST": "(?:%{IP:destination.ip})(:%{NUMBER:destination.port})?",`
- `"NGINX_NOTSEPARATOR": "\"\"[^\s,:]+\"\"",`
- `"NGINX_ADDRESS_LIST": "\"\"(?:%{IP}|%{WORD})(\"?,?\s*(?:%{IP}|%{WORD}))\"*\"\"",`
- `}`

日志收集与分析

- `(%{NGINX_HOST} )?"?`
- 可选项，匹配 `NGINX_HOST` 或空格
- `(?: ... )`
- 是非捕获分组，用于匹配 IP 地址或者 `NGINX_NOTSEPARATOR` 定义的域名
- `%{IP:destination.ip}`
- 匹配 IP 地址，并将其存储到 `destination.ip` 字段
- `(: %{NUMBER:destination.port})?`
- 匹配可选的端口号，并将其存储到 `destination.port` 字段

日志收集与分析

- `(%{NGINX_HOST} )?"?`
- `NGINX_NOTSEPARATOR`
- 用于定义 NGINX 主机中不能是分隔符的部分
- `NGINX_ADDRESS_LIST`
- 用于匹配 NGINX 主机地址列表
- `(?:%{IP}|%{WORD})` 匹配 IP 地址或者单词 (WORD)
- `("?,?\s*(?:%{IP}|%{WORD}))*` 是一个重复模式, 用于匹配多个地址, 包括逗号、空格等分隔符

日志收集与分析

- `\[%{HTTPDATE:nginx.access.time}\]`
- 匹配日期时间，格式为 HTTPDATE，提取到 `nginx.access.time` 字段
- `"%{DATA:nginx.access.info}"`
- 匹配任意数据作为 `nginx.access.info` 字段的值
- `%{NUMBER:http.response.status_code:long}`
- 匹配 HTTP 响应状态码，存储为 `long` 类型的 `http.response.status_code`

日志收集与分析

- 对nginx.access.info再次进行GORK
- "GET /epel/9/Everything/x86_64/Packages/g/ghc-js-dgtable-devel-0.5.2-23.el9.x86_64.rpm HTTP/2.0"
- `%{WORD:http.request.method} %{DATA:url.path}`
`HTTP/%{NUMBER:http.version}`
- `url.original`里再次细分
- `/%{DATA:http.request.repo}/`
- 其余GORK同理

日志收集与分析


- `(%{NGINX_HOST})?"?(?:%{NGINX_ADDRESS_LIST:nginx.access.remote_ip_list}|%{NOTSPACE:source.address}) - (-|{%{DATA:user.name}})\[%{HTTPDATE:nginx.access.time}\] "%{DATA:nginx.access.info}"
%{NUMBER:http.response.status_code:long}
%{NUMBER:http.response.body.bytes:long} "(-
|{%{DATA:http.content.type}})" "(-
|{%{DATA:http.request.referrer}})" "(-
|{%{DATA:user_agent.original}})" - (-|{%{DATA:http.scheme}}) "(-
|{%{DATA:http.url.domain}})" - "(-
|{%{NUMBER:http.request.time:float}})" "(-
|{%{NUMBER:http.upstream_response.time:float}})" "(-
|{%{NOTSPACE:http.xff}})`
- `'$remote_addr - $remote_user [$time_local] "$request" $status $body_bytes_sent
"$sent_http_content_type" "$http_referer" "$http_user_agent" - $scheme "$host" -
"$request_time" "$upstream_response_time" "$http_x_forwarded_for"`

日志可视化展示

- 在Grafana中新增数据源，索引名为filebeat-*
- 新建dashboard (mirrorslog) 进行总体数据展示
- 新建变量
- Domain : `{"find":"terms","field":"http.url.domain"}`
- 创建Ad hoc filters类型变量

日志可视化展示

- VIP是需要重点关注的对象！！



日志可视化展示

访问 PV (相对)



访问 UV (相对)



All => 平均响应时间(s)



基本概况 (相对)

域名	pv	uv	处理时间(s)	响应时间(s)	出站流量之和
mirror.nyist.edu.cn	4,104,594	209,905	4.01	2.456	7.09 TB
mirror4.nyist.edu.cn	4,116	1,363	7.223	0.738	12.1 GB
mirrors.nyist.edu.cn	10,109	29	3.219	0.465	1.84 GB
mirror6.nyist.edu.cn	408	56	0.248	0.304	831 MB

All => 国家/地区访问占比



All => 访问前十的省份



All => 访问前十的城市



All => VIP TOP 10




All 系统 TOP 10



All 移动端 TOP 10



日志可视化展示




日志可视化展示

历史趋势


All 请求数



All 请求方法占比




All HTTP 状态码



Name	Max	Total
200	81872	2779369
206	17439	621226
404	9057	473282
304	1363	20031
301	33	1421
416	61	992
499	25	552
405	137	175
302	42	76
400	4	25

状态码饼图




日志可视化展示

Nginx request



Nginx repo Bytes



数据报表分析

All => 客户端数据详请


客户端IP	请求次数	uri总数(count)	返回客户端总流量
36.139. [REDACTED]	72	4	61.74 GB
36.139. [REDACTED]	37	4	58.93 GB
115.192. [REDACTED]	779	757	43.38 GB
121.4. [REDACTED]	13,740	8	36.31 GB
106.39. [REDACTED]	69	2	25.17 GB
111.18. [REDACTED]	68	18	22.86 GB
219.143. [REDACTED]	17	13	22.73 GB
2408:8221. [REDACTED]	4	1	22.71 GB
119.136. [REDACTED]	2	1	22.70 GB

Request Uri 数据详请

请求URL名称	请求总数(pv)	ip总数(uv)	返回客户端流量 ↓	平均响应时间(s)
/centos-stream/9-stream/BaseOS/x86_64/iso/CentOS-	14,538	588	2.04 TB	1.94 mins
/ubuntu-releases/24.04/ubuntu-24.04-desktop-amd64	1,039	170	617.46 GB	5.11 mins
/fedora/releases/39/Workstation/x86_64/iso/Fedora-W	4,160	590	384.54 GB	52.9 s
/epel/8/Everything/x86_64/repodata/cb3c021daed1f23	19,320	10,963	205.99 GB	14.6 s
/fedora/releases/40/Workstation/x86_64/iso/Fedora-W	1,249	151	163.79 GB	4.00 mins
/rocky/8.10/AppStream/x86_64/os/repodata/293d7a3b	19,219	6,862	159.93 GB	3.49 s
/centos-stream/9-stream/BaseOS/aarch64/iso/CentOS	1,258	66	151.41 GB	1.81 mins
/epel/8/Everything/x86_64/repodata/3e09cb5febaec7	14,118	7,798	150.83 GB	16.2 s
/epel/9/Everything/x86_64/repodata/5d56cd107f83d2	6,692	4,732	110.45 GB	15.5 s

日志可视化展示

- 对单个 IP/CIDR 的行为进行分析
- UA
- Repo
- Referer
- 以 UA_Device 为例



~ A (Elasticsearch)


Query type: Metrics Logs Raw Data Raw Document

Lucene Query: http.url.domain:\$domain Alias: Alias Pattern

Metric (1)	Sum	http.response.body.bytes	> Options +
Group By	Terms	user_agent.device.name	> Min Doc Count: 1, Order by: Term value (desc) +
Then By	Date Histogram	@timestamp	> Interval: auto


日志可视化展示

- 通过filter来对各个panel进行细分查询




日志可视化展示

- 使用CIDR地址段



日志可视化展示

- 使用CIDR地址段



后续工作

- 恶意流量对策联合工作小组：依靠大脸萌
- 能否将各高校镜像站的日志统计在一起发现潜在问题
- 性能调优、故障转移
- 镜像站双机热备列入实验项目

讨论/提问

