Elasticsearch

作者：老男孩 Linux 教育-张亚

归档：上课文档

2019/7/08

快捷键：

Ctrl + 1 标题 1
Ctrl + 2 标题 2
Ctrl + 3 标题 3
Ctrl + 4 实例
Ctrl + 5 程序代码
Ctrl + 6 正文

格式说明：

蓝色字体：注释

黄色背景：重要

绿色背景：注意

目　录

第1章 为什么

1.1 几个问题

1.什么是搜索？
2.如果用数据库做搜索会怎么样？
3.什么是全文检索和 Lucene?
4.什么是 Elasticsearch？

1.2 什么是搜索？

百度：我们比如说想找寻任何的信息的时候，就会去上百度搜索一下，比如搜一本书，一部电影（提到搜索的第一印象）
百度 = 搜索，这是不对的
垂直搜索（站内搜索）
互联网的搜索，电商网站，各种 APP
IT 系统的搜索，OA 软件，

1.3 如果用数据库做搜索会怎么样？

做软件开发的话，或者对 IT，计算机有一定了解的话，都知道，数据都是存储在数据库里面的，比如说电商网站的商品信息，招聘网站的职位信息，新闻网站的新闻信息
1.比方说，每条记录的指定字段的文本，可能会很长，比如说“商品描述”字段的长度，有长达数千个，甚至数万个字符，这个时候，每次都要对每条记录的所有文本进行扫描，来判断说，你包不包含我指定的这个关键词，比如说：牙膏
2.还不能将搜索词拆分开来，尽可能去搜索更多的符合你的期望的结果，比如说：输入“生化机”，就搜不出来“生化危机”。
结论：
用数据库来实现搜索，是不太靠谱的，通常来说，性能会很差

1.4 什么是全文检索和 Lucene?

1.老男孩教育
2.老男孩教育 linux 学院
3.老男孩教育 python 学院
4.老男孩教育 DBA
5.老男孩教育 oldzhang

关键词	ids
老男孩	1，2，3，4，5
教育	1，2，3，4，5
学院	2，3
linux	2
python	3
DBA	4
oldzhang	5

1.5 什么是 Elasticsearch

您往下看

第2章 Elasticsearch 介绍

2.1 elasticsearch 介绍

Elasticsearch 是一个实时的分布式搜索分析引擎， 它能让你以一个之前从未有过的速度和规模，去探索你的数据。 它被用作全文检索、结构化搜索、分析以及这三个功能的组合

Elasticsearch 是一个基于 Apache Lucene(TM)的开源搜索引擎。无论在开源还是专有领域，Lucene 可以被认为是迄今为止最先进、性能最好的、功能最全的搜索引擎库。 但是，Lucene 只是一个库。想要使用它，你必须使用 Java 来作为开发语言并将其直接集成到你的应用中，更糟糕的是，Lucene 非常复杂，你需要深入了解检索的相关知识来理解它是如何工作的。 Elasticsearch 也使用 Java 开发并使用 Lucene 作为其核心来实现所有索引和搜索的功能，但是它的目的是通过简单的 RESTful API 来隐藏 Lucene 的复杂性，从而让全文搜索变得简单。

2.2 elasticsearch 功能

（1）分布式的搜索引擎和数据分析引擎

搜索：百度，网站的站内搜索，IT 系统的检索

数据分析：电商网站，最近 7 天牙膏这种商品销量排名前 10 的商家有哪些；新闻网站，最近 1 个月访问量排名前 3 的新闻版块是哪些

分布式，搜索，数据分析

（2）全文检索，结构化检索，数据分析

全文检索：我想搜索商品名称包含牙膏的商品，select * from products where product_name like "%牙膏%"

结构化检索：我想搜索商品分类为日化用品的商品都有哪些，select * from products where category_id='日化用品'

部分匹配、自动完成、搜索纠错、搜索推荐

数据分析：我们分析每一个商品分类下有多少个商品，select category_id,count(*) from products group by category_id

（3）对海量数据进行近实时的处理

分布式：ES 自动可以将海量数据分散到多台服务器上去存储和检索

海联数据的处理：分布式以后，就可以采用大量的服务器去存储和检索数据，自然而然就可以实现海量数据的处理了

近实时：检索个数据要花费 1 小时（这就不要近实时，离线批处理，batch-processing）；在秒级别对数据进行搜索和分析

跟分布式/海量数据相反的：lucene，单机应用，只能在单台服务器上使用，最多只能处理单台服务器可以处理的数据量

2.3 elasticsearch 应用场景

国外

（1）维基百科，类似百度百科，牙膏，牙膏的维基百科，全文检索，高亮，搜索推荐

（2）The Guardian（国外新闻网站），类似搜狐新闻，用户行为日志（点击，浏览，收藏，评论）+社交网络数据（对某某新闻的相关看法），数据分析，给到每篇新闻文章的作者，让他知道他的文章的公众反馈（好，坏，热门，垃圾，鄙视，崇拜）

（3）Stack Overflow（国外的程序异常讨论论坛），IT 问题，程序的报错，提交上去，有人会跟你讨论和回答，全文检索，搜索相关问题和答案，程序报错了，就会将报错信息粘贴到里面去，搜索有没有对应的答案

（4）GitHub（开源代码管理），搜索上千亿行代码

（5）电商网站，检索商品

（6）日志数据分析，logstash 采集日志，ES 进行复杂的数据分析（ELK 技术，elasticsearch+logstash+kibana）

（7）商品价格监控网站，用户设定某商品的价格阈值，当低于该阈值的时候，发送通知消息给用户，比如说订阅牙膏的监控，如果高露洁牙膏的家庭套装低于 50 块钱，就通知我，我就去买

（8）BI 系统，商业智能，Business Intelligence。比如说有个大型商场集团，BI，分析一下某某区域最近 3 年的用户消费金额的趋势以及用户群体的组成构成，产出相关的数张报表，**区，最近 3 年，每年消费金额呈现 100%的增长，而且用户群体 85%是高级白领，开一个新商场。ES 执行数据分析和挖掘，Kibana 进行数据可视化

国内

（9）国内：站内搜索（电商，招聘，门户，等等），IT 系统搜索（OA，CRM，ERP，等等），数据分析（ES 热门的一个使用场景）

2.4 Elasticsearch 的特点

（1）可以作为一个大型分布式集群（数百台服务器）技术，处理 PB 级数据，服务大公司；也可以运行在单机上，服务小公司

（2）Elasticsearch 不是什么新技术，主要是将全文检索、数据分析以及分布式技术，合并在了一起，才形成了独一无二的 ES；lucene（全文检索），商用的数据分析软件（也是有的），分布式数据库（mycat）

（3）对用户而言，是开箱即用的，非常简单，作为中小型的应用，直接 3 分钟部署一下 ES，就可以作为生产环境的系统来使用了，数据量不大，操作不是太复杂

（4）数据库的功能面对很多领域是不够用的（事务，还有各种联机事务型的操作）；特殊的功能，比如全文检索，同义词处理，相关度排名，复杂数据分析，海量数据的近实时处理；Elasticsearch 作为传统数据库的一个补充，提供了数据库所不不能提供的很多功能

2.5 数据格式

Elasticsearch 使用 JavaScript Object Notation 或者 JSON 作为文档的序列化格式。JSON 序列化被大多数编程语言所支持，并且已经成为 NoSQL 领域的标准格式。 它简单、简洁、易于阅读。

考虑一下这个 JSON 文档，它代表了一个 user 对象:

```
{
"email": "john@smith.com", "first_name": "John",
"last_name": "Smith",
"info":
        { "bio": "Eco-warrior and defender of the weak",
        "age": 25,
        "interests": [ "dolphins", "whales" ]
        },
"join_date": "2014/05/01"
}
```

第3章 安装

3.1 几种安装方式介绍

官方文档

https://www.elastic.co/guide/en/elasticsearch/reference/current/install-elasticsearch.html

安装方式	优点	缺点
docker	1.部署方便 2.开箱即用 3.启动迅速	1.需要有docker的知识 2.修改配置麻烦，需要重新生成镜像 3.数据存储需要挂载目录
tar	1.部署灵活 2.对系统的侵占性小	1.需要自己写启动管理文件 2.目录提前需要规划好
Rpm|deb	1.部署方便 2.启动脚本安装即用 3.存放目录标准化	1.软件各个组件分散在不同的目录 2.卸载可能不干净 3.默认配置需要修改
ansible	1.极其的灵活 2.你想要的功能都有 3.批量部署速度快	1.需要学习ansible语法和规则 2.需要提前规划好所有的标准 3.需要专人维护

3.1.1 java 安装

```
yum install java
```

3.1.2 软件包安装

```
wget https://artifacts.elastic.co/downloads/elasticsearch/elasticsearch-6.4.2.rpm
rpm -ivh elasticsearch-6.4.2.rpm
systemctl daemon-reload
systemctl enable elasticsearch.service
systemctl start elasticsearch.service
systemctl status elasticsearch.service
ps -ef|grep elastic
lsof -i:9200
```

3.1.3 tar 安装

```

```

3.1.4 docker 安装

```

```

3.2 测试是否安装成功

```
[root@elk-75 elasticsearch]# curl 'http://localhost:9200/?pretty'
```

```
{
  "name" : "KhcOKcU",
  "cluster_name" : "elasticsearch",
  "cluster_uuid" : "tTJ0Rmc0Qp6oB-Sx6euCIA",
  "version" : {
    "number" : "6.4.2",
    "build_flavor" : "default",
    "build_type" : "rpm",
    "build_hash" : "04711c2",
    "build_date" : "2018-09-26T13:34:09.098244Z",
    "build_snapshot" : false,
    "lucene_version" : "7.4.0",
    "minimum_wire_compatibility_version" : "5.6.0",
    "minimum_index_compatibility_version" : "5.0.0"
  },
  "tagline" : "You Know, for Search"
}
```

第4章 重要配置

4.1 相关配置目录以及配置文件

```
rpm -ql elasticsearch                    #查看 elasticsearch 软件安装了哪些目录
/etc/elasticsearch/elasticsearch.yml     #配置文件
/etc/elasticsearch/jvm.options           #jvm 虚拟机配置文件
/etc/init.d/elasticsearch                #init 启动文件
/etc/sysconfig/elasticsearch             #环境变量配置文件
/usr/lib/sysctl.d/elasticsearch.conf     #sysctl 变量文件，修改最大描述符
/usr/lib/systemd/system/elasticsearch.service   #systemd 启动文件
/var/lib/elasticsearch                   #  数据目录
/var/log/elasticsearch                   #日志目录
/var/run/elasticsearch                   #pid 目录
```

4.2 elsticsrach 配置文件解读

Elasticsearch 已经有了很好的默认值，特别是涉及到性能相关的配置或者选项,其它数据库可能需要调优，但总得来说，Elasticsearch 不需要。如果你遇到了性能问题，解决方法通常是更好的数据布局或者更多的节点。

```
[root@elk-75 elasticsearch]# egrep -v "^#" elasticsearch.yml
```

```
cluster.name: dba5
node.name: node-1
path.data: /data/elasticsearch
path.logs: /var/log/elasticsearch
bootstrap.memory_lock: true
network.host: 192.168.47.75
http.port: 9200
discovery.zen.ping.unicast.hosts: ["192.168.47.75"]
discovery.zen.minimum_master_nodes: 2
```

4.3 修改配置重新启动

```
mkdir /data/elasticsearch
chown -R elasticsearch:elasticsearch /data/elasticsearch/
systemctl restart elasticsearch
systemctl status elasticsearch
```

4.4 锁定内存失败解决

官方解决方案

```
https://www.elastic.co/guide/en/elasticsearch/reference/6.4/setup-configuration-memory.html
https://www.elastic.co/guide/en/elasticsearch/reference/6.4/setting-system-settings.html#sysconfig
### 修改启动配置文件
vim /usr/lib/systemd/system/elasticsearch.service
### 增加如下参数
[Service]
LimitMEMLOCK=infinity
### 重新启动
systemctl daemon-reload
systemctl restart elasticsearch
```

第5章 elasticseartch 术语及概念

5.1 索引词

在 elastiasearch 中索引词（term）是一个能够被索引的精确值。foo,Foo,FOO 几个单词是不同的索引词。索引词（term）是可以通过 term 查询进行准确的搜索。

5.2 文本(text)

文本是一段普通的非结构化文字。通常，文本会被分拆成一个个的索引词，存储在 elasticsearch 的索引库中。为

了让文本能够进行搜索，文本字段需要事先进行分析了；当对文本中的关键词进行查询的时候，搜索引擎应该根据搜索条件搜索出原文本。

5.3 分析(analysis)

分析是将文本转换为索引词的过程，分析的结果依赖于分词器。比如：FOO BAR，Foo-Bar 和 foo bar 这几个词有可能会被分析成相同的索引词 foo 和 bar，这些索引词存储在 Elasticsearch 的索引库中。

5.4 集群(cluster)

集群由一个或多个节点组成，对外提供服务，对外提供索引和搜索功能。在所有节点，一个集群有一个唯一的名称默认为“elasticsearch”.此名称是很重要的，因为每个节点只能是集群的一部分，当该节点被设置为相同的集群名称时，就会自动加入集群。当需要有多个集群的时候，要确保每个集群的名称不能重复，，否则节点可能会加入到错误的集群。请注意，一个节点只能加入到一个集群。此外，你还可以拥有多个独立的集群，每个集群都有其不同的集群名称。

5.5 节点(node)

一个节点是一个逻辑上独立的服务,它是集群的一部分,可以存储数据,并参与集群的索引和搜索功能。就像集群一样,节点也有唯一的名字,在启动的时候分配。如果你不想要默认名称,你可以定义任何你想要的节点名.这个名字在理中很重要,在 Elasticsearch 集群通过节点名称进行管理和通信.一个节点可以被配置加入到一个特定的集群。默认情况下,每个节点会加人名为 Elasticsearch 的集祥中,这意味着如果你在网热动多个节点,如果网络畅通,他们能彼此发现井自动加人名为 Elasticsearch 的一个集群中,你可以拥有多个你想要的节点。当网络没有集祥运行的时候,只要启动一个节点,这个节点会默认生成一个新的集群,这个集群会有一个节点。

5.6 分片(shard)

分片是单个 Lucene 实例,这是 Elasticsearch 管理的比较底层的功能。索引是指向主分片和副本分片的逻辑空间。 对于使用,只需要指定分片的数量,其他不需要做过多的事情。在开发使用的过程中,我们对应的对象都是索引,Elasticsearch 会自动管理集群中所有的分片,当发生故障的时候,Elasticsearch 会把分片移动到不同的节点或者添加新的节点。

一个索引可以存储很大的数据,这些空间可以超过一个节点的物理存储的限制。例如,十亿个文档占用磁盘空间为 1TB。仅从单个节点搜索可能会很慢,还有一台物理机器也不一定能存储这么多的数据。为了解决这一问题,Elasticsearch 将索引分解成多个分片。当你创建一个索引,你可以简单地定义你想要的分片数量。每个分片本身是一个全功能的、独立的单元,可以托管在集群中的任何节点。

5.7 主分片

每个文档都存储在一个分片中,当你存储一个文档的时候,系统会首先存储在主分片中,然后会复制到不同的副本中。默认情况下,一个索引有 5 个主分片。 你可以事先制定分片的数量,当分片一旦建立,则分片的数量不能修改。

5.8 副本分片

每一个分片有零个或多个副本。副本主要是主分片的复制,其中有两个目的:

- 增加高可用性:当主分片失败的时候,可以从副本分片中选择一个作为主分片。

- 提高性能:当查询的时候可以到主分片或者副本分片中进行查询。默认情况下,一个主分片配有一个副本,但副本的数量可以在后面动态地配置增加。副本分片必部署在不同的节点上,不能部署在和主分片相同的节点上。

分片主要有两个很重要的原因是:
- 允许水平分割扩展数据。
- 允许分配和并行操作(可能在多个节点上)从而提高性能和吞吐量。

这些很强大的功能对用户来说是透明的,你不需要做什么操作,系统会自动处理。

5.9 复制

复制是一个非常有用的功能,不然会有单点问题。 当网络中的某个节点出现问题的时候,复制可以对故障进行转移,保证系统的高可用。因此,Elasticsearch 允许你创建一个或多个拷贝,你的索引分片就形成了所谓的副本或副本分片。

复制是重要的,主要的原因有:
- 它提供丁高可用性,当节点失败的时候不受影响。需要注意的是,一个复制的分片不会存储在同一个节点中。
- 它允许你扩展搜索量,提高并发量,因为搜索可以在所有副本上并行执行。

每个索引可以拆分成多个分片。索引可以复制零个或者多个分片。一旦复制,每个索引就有了主分片和副本分片。分片的数量和副本的数量可以在创建索引时定义。 当创建索引后,你可以随时改变副本的数量,但你不能改变分片的数量。

默认情况下,每个索引分配 5 个分片和一个副本,这意味着你的集群节点至少要有两个节点,你将拥有 5 个主要的分片和 5 个副本分片共计 10 个分片.

每个 Elasticsearch 分片是一个 Lucene 的索引。有文档存储数量限制,你可以在一个单一的 Lucene 索引中存储的最大值为 lucene-5843,极限是 2147483519(=integer.max_value-128)个文档。你可以使用 cat/shards API 监控分片的大小。

5.10 索引

索引是具有相同结构的文档集合。例如,可以有一个客户信息的索引,包括一个产品目录的索引,一个订单数据的索引。 在系统上索引的名字全部小写,通过这个名字可以用来执行索引、搜索、更新和删除操作等。在单个集群中,可以定义多个你想要的索引。

5.11 类型

在索引中,可以定义一个或多个类型,类型是索引的逻辑分区。在一般情况下,一种类型被定义为具有一组公共字段的文档。例如,让我们假设你运行一个博客平台,并把所有的数据存储在一个索引中。在这个索引中,你可以定义一种类型为用户数据,一种类型为博客数据,另一种类型为评论数据。

5.12 文档

文档是存储在 Elasticsearch 中的一个 JSON 格式的字符串。它就像在关系数据库中表的一行。每个存储在索引中的一个文档都有一个类型和一个 ID,每个文档都是一个 JSON 对象,存储了零个或者多个字段,或者键值对。原始的 JSON 文档假存储在一个叫作 Sour 的字段中。当搜索文档的时候默认返回的就是这个字

段。

5.13 映射

映射像关系数据库中的表结构,每一个索引都有一个映射,它定义了索引中的每一个字段类型,以及一个索引范围内的设置。一个映射可以事先被定义,或者在第一次存储文档的时候自动识别。

5.14 字段

文档中包含零个或者多个字段,字段可以是一个简单的值(例如字符串、整数、日期),也可以是一个数组或对象的嵌套结构。字段类似于关系数据库中表的列。每个字段都对应一个字段类型,例如整数、字符串、对象等。字段还可以指定如何分析该字段的值。

5.15 主键

ID 是一个文件的唯一标识,如果在存库的时候没有提供 ID,系统会自动生成一个 ID,文档的 index/type/id 必须是唯一的。

5.16 elasticsearch 和数据库的对应关系

Elasticsearch	数据库
Index	库
Type	表
Document	行

第6章 交互

6.1 交互方式

所有其他语言可以使用 RESTful API 通过端口 9200 和 Elasticsearch 进行通信，你可以用你最喜爱的 web 客户端访问 Elasticsearch.事实上，正如你所看到的，你甚至可以使用 curl 命令来和 Elasticsearch 交互 。

一个 Elasticsearch 请求和任何 HTTP 请求一样由若干相同的部件组成:

```
curl -X<VERB> '<PROTOCOL>://<HOST>:<PORT>/<PATH>?<QUERY_STRING>' -d '<BODY>'
```

VERB 适当的 HTTP 方法 或 谓词 : GET`、 `POST`、 `PUT`、 `HEAD 或者 `DELETE`。 PROTOCOL http 或者 https`(如果你在 Elasticsearch 前面有一个 `https 代理)

HOST Elasticsearch 集群中任意节点的主机名，或者用 localhost 代表本地机器上的节点。

PORT 运行 Elasticsearch HTTP 服务的端口号，默认是 9200 。

PATH API 的终端路径(例如 _count 将返回集群中文档数量)。Path 可能包含多个组件，例如: _cluster/stats 和 _nodes/stats/jvm 。

QUERY_STRING 任意可选的查询字符串参数 (例如 ?pretty 将格式化地输出 JSON 返回值，使其更容易 阅读)

BODY 一个 JSON 格式的请求体 (如果请求需要的话)

6.2 通用参数

6.2.1 pretty 参数

当你在任何请求中添加了参数?pretty=true 时，请求的返回值是经过格式化后的 JSON 数据，这样阅读起来更加方便。
系统还提供了另一种格式的格式化，?format=yaml,YAML 格式，这将导致返回的结果具有可读的 YAML 格式。

6.2.2 human 参数

对于统计数据，系统支持计算机数据，同时也支持比较适合人类阅读的数据。?human=true，默认是 false

6.2.3 响应过滤 filter_path

所有的返回值通过 filter_path 减少返回值的内容，多个值可以用逗号分开。也可以使用通配符*

6.3 curl 命令行交互

6.3.1 计算文档数量

```
[root@elk-75 ~]# curl -XGET 'http://192.168.47.75:9200/_count?pretty' -H 'Content-Type:
application/json' -d '
{
  "query": { "match_all": {}
  }
}
'
{
  "count" : 0,
  "_shards" : {
    "total" : 0,
    "successful" : 0,
    "skipped" : 0,
    "failed" : 0
  }
}
```

6.4 es-head 插件交互

6.4.1 插件官方地址

```
https://github.com/mobz/elasticsearch-head
```

6.4.2 使用 docker 部署 elasticsearch-head

```
docker pull alivv/elasticsearch-head
docker run --name es-head -p 9100:9100 -dit elivv/elasticsearch-head
```

6.4.3 使用 nodejs 编译安装

官网地址

```
https://nodejs.org/en/download/package-manager/
https://nodejs.org/dist/latest-v10.x/
http://npm.taobao.org
```

下载安装

```
yum install nodejs npm openssl screen -y
node -v
npm  -v
npm install -g cnpm --registry=https://registry.npm.taobao.org
cd /opt/
git clone git://github.com/mobz/elasticsearch-head.git
cd elasticsearch-head/
cnpm install
screen -S es-head
cnpm run start
Ctrl+A+D
```

6.4.4 修改 ES 配置文件支持跨域

```
http.cors.enabled: true
http.cors.allow-origin: "*"
```

6.4.5 网页访问

IP 地址:9100

6.5 kibana 交互

6.5.1 安装配置 kibana

```
wget https://artifacts.elastic.co/downloads/kibana/kibana-6.4.2-x86_64.rpm
rpm -ivh kibana-6.4.2-x86_64.rpm
[root@elk-75 soft]# grep "^[a-Z]" /etc/kibana/kibana.yml
server.port: 5601
server.host: "192.168.47.75"
elasticsearch.url: "http://192.168.47.75:9200"
kibana.index: ".kibana"
[root@elk-75 soft]# systemctl start kibana
[root@elk-75 soft]# systemctl status kibana
[root@elk-75 soft]# lsof -i:5601
COMMAND    PID    USER    FD    TYPE DEVICE SIZE/OFF NODE NAME
node     44667 kibana    12u   IPv4  72918      0t0  TCP 192.168.47.75:esmagent (LISTEN)
```

6.5.2 创建索引

6.5.3 过滤查询数据

第7章 相关操作 API

7.1 文档相关的 API

官网地址：

```
https://www.elastic.co/guide/en/elasticsearch/reference/current/indices.html
```

7.1.1 创建索引文档

7.1.2 插入数据

```
[root@elk-75 scripts]# cat input_elk.sh
#!/bin/bash
curl -XPUT '192.168.47.75:9200/megacorp/employee/1?pretty' -H 'Content-Type: application/json' -d'
{
    "first_name" : "John",
    "last_name": "Smith",
    "age" : 25,
    "about" : "I love to go rock climbing", "interests": [ "sports", "music" ]
}
'
curl -XPUT '192.168.47.75:9200/megacorp/employee/2?pretty' -H 'Content-Type: application/json' -d' {
"first_name": "Jane",
"last_name" : "Smith",
"age" : 32,
"about" : "I like to collect rock albums", "interests": [ "music" ]
}
'
curl -XPUT '192.168.47.75:9200/megacorp/employee/3?pretty' -H 'Content-Type: application/json' -d' {
"first_name": "Douglas", "last_name" : "Fir",
"age" : 35,
"about": "I like to build cabinets", "interests": [ "forestry" ]
} '
[root@elk-75 scripts]# bash input_elk.sh
{
  "_index" : "megacorp",
  "_type" : "employee",
  "_id" : "1",
  "_version" : 2,
  "result" : "updated",
  "_shards" : {
    "total" : 2,
    "successful" : 2,
    "failed" : 0
  },
  "_seq_no" : 1,
  "_primary_term" : 1
```

```
}
{
  "_index" : "megacorp",
  "_type" : "employee",
  "_id" : "2",
  "_version" : 1,
  "result" : "created",
  "_shards" : {
    "total" : 2,
    "successful" : 2,
    "failed" : 0
  },
  "_seq_no" : 0,
  "_primary_term" : 1
}
{
  "_index" : "megacorp",
  "_type" : "employee",
  "_id" : "3",
  "_version" : 1,
  "result" : "created",
  "_shards" : {
    "total" : 2,
    "successful" : 2,
    "failed" : 0
  },
  "_seq_no" : 0,
  "_primary_term" : 1
}
```

7.1.3 查询文档

```
#查询某一条数据
[root@elk-75 scripts]# curl -XGET '192.168.47.75:9200/megacorp/employee/1?pretty'
{
  "_index" : "megacorp",
  "_type" : "employee",
  "_id" : "1",
  "_version" : 1,
```

```
  "found" : true,
  "_source" : {
    "first_name" : "John",
    "last_name" : "Smith",
    "age" : 25,
    "about" : "I love to go rock climbing",
    "interests" : [
      "sports",
      "music"
    ]
  }
}
```

7.1.4 删除文档

```
#删除某条文档
[root@elk-75 scripts]# curl -XDELETE '192.168.47.75:9200/megacorp/employee/1?pretty'
{
  "_index" : "megacorp",
  "_type" : "employee",
  "_id" : "1",
  "_version" : 3,
  "result" : "deleted",
  "_shards" : {
    "total" : 2,
    "successful" : 2,
    "failed" : 0
  },
  "_seq_no" : 2,
  "_primary_term" : 1
}
```

7.2 索引相关 API

7.2.1 创建索引

```
[root@elk-75 scripts]# curl -XPUT '192.168.47.75:9200/megacorp?pretty'
{
  "acknowledged" : true,
  "shards_acknowledged" : true,
```

```
  "index" : "megacorp"
}
```

7.2.2 查询索引信息

```
#查询索引中所有的信息
curl -XGET '192.168.47.75:9200/megacorp/employee/_search?pretty'
#查询索引符合条件的信息：搜索姓名为：Smith 的员工
curl -XGET '192.168.47.75:9200/megacorp/employee/_search?q=last_name:Smith&pretty'
#使用 Query-string 查询
curl -XGET '192.168.47.75:9200/megacorp/employee/_search?pretty' -H 'Content-Type: application/json'
-d'
{
"query" : { "match" : {
"last_name" : "Smith" }
} }
'
#使用过滤器
curl -XGET '192.168.47.75:9200/megacorp/employee/_search?pretty' -H 'Content-Type: application/json'
-d'
{
"query" : { "bool": {
"must": { "match" : {
"last_name" : "smith" }
}, "filter": {
"range" : {
"age" : { "gt" : 30 }
} }
} }
}
'
```

7.2.3 删除索引

```
#删除整个索引
[root@elk-75 scripts]# curl -XDELETE '192.168.47.75:9200/megacorp?pretty'
{
  "acknowledged" : true
}
```

第8章 集群管理

8.1 集群配置文件解读

```
[root@elk-75 ~]# grep -v "^#" /etc/elasticsearch/elasticsearch.yml
cluster.name: dba5
node.name: node-1
path.data: /data/elasticsearch
path.logs: /var/log/elasticsearch
bootstrap.memory_lock: true
network.host: 192.168.47.75
http.port: 9200
discovery.zen.ping.unicast.hosts: ["192.168.47.75","192.168.47.76","192.168.47.77"]
discovery.zen.minimum_master_nodes: 1
http.cors.enabled: true
http.cors.allow-origin: "*"
```

8.2 集群的相关 API

8.2.1 查看集群健康状况

查看集群健康状况：

官网地址：

```
https://www.elastic.co/guide/en/elasticsearch/reference/current/cluster-health.html
```

操作命令：

```
[root@elk-75 ~]# curl -XGET 'http://192.168.47.75:9200/_cluster/health?pretty'
{
  "cluster_name" : "dba5",
  "status" : "green",
  "timed_out" : false,
  "number_of_nodes" : 3,
  "number_of_data_nodes" : 3,
  "active_primary_shards" : 0,
  "active_shards" : 0,
  "relocating_shards" : 0,
  "initializing_shards" : 0,
  "unassigned_shards" : 0,
  "delayed_unassigned_shards" : 0,
```

```
  "number_of_pending_tasks" : 0,
  "number_of_in_flight_fetch" : 0,
  "task_max_waiting_in_queue_millis" : 0,
  "active_shards_percent_as_number" : 100.0
}
```

8.2.2 查看系统检索信息

Cluster Stats API 允许从群集范围的角度检索统计信息。

官网地址：

```
https://www.elastic.co/guide/en/elasticsearch/reference/current/cluster-stats.html
```

操作命令：

```
[root@elk-75 ~]# curl -XGET 'http://192.168.47.75:9200/_cluster/stats?human&pretty'
```

8.2.3 查看集群的设置

官方地址：

```
https://www.elastic.co/guide/en/elasticsearch/reference/current/cluster-get-settings.html
```

操作命令：

```
curl -XGET 'http://192.168.47.75:9200/_cluster/settings?include_defaults=true&human&pretty'
```

8.2.4 查询节点的状态

官网地址：

```
https://www.elastic.co/guide/en/elasticsearch/reference/current/cluster-nodes-info.html
```

操作命令：

```
curl -XGET 'http://192.168.47.75:9200/_nodes/procese?human&pretty'
curl -XGET 'http://192.168.47.75:9200/_nodes/_all/info/jvm,process?human&pretty'
[root@elk-75 ~]# curl -XGET 'http://192.168.47.75:9200/_cat/nodes?human&pretty'
192.168.47.76 21 96 0 0.02 0.04 0.05 mdi - node-2
192.168.47.77 19 95 0 0.00 0.01 0.05 mdi * node-3
192.168.47.75 36 85 0 0.07 0.06 0.19 mdi - node-1
```

8.2.5 索引分片

```
curl -XPUT '192.168.47.75:9200/blogs?pretty' -H 'Content-Type: application/json' -d'
{
"settings" : {
    "number_of_shards" : 3,
    "number_of_replicas" : 1
```

```
 }
}'
```

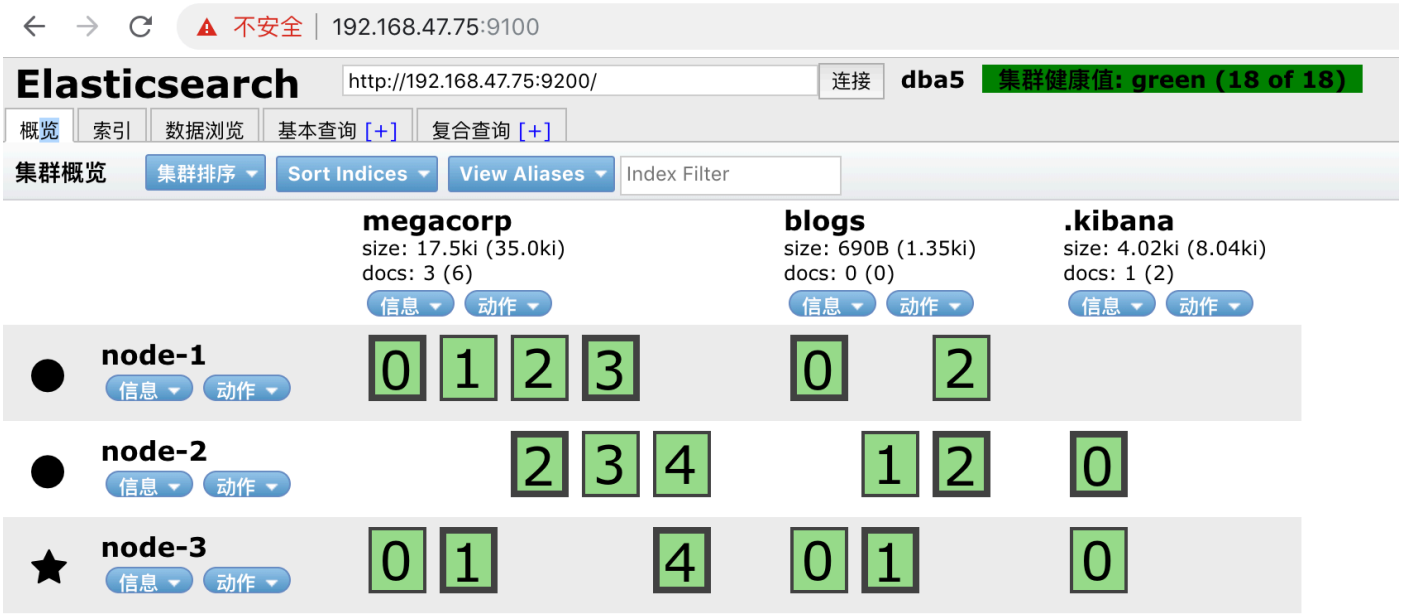

8.2.6 调整副本数

分片数一旦创建就不能再更改了，但是我们可以调整副本数

```
curl -XPUT '192.168.47.75:9200/index2/_settings?pretty' -H 'Content-Type: application/json' -d'
{
"settings" : {
"number_of_replicas" : 2
}
}
```

8.3 负载均衡与高可用

第9章 监控

9.1 x-pack

9.2 search guard 权限管理

第10章 集群运维

10.1 滚动升级

10.2 备份与恢复

第11章 项目分享

11.1 中文分词器

11.1.1 官方地址

```
https://github.com/medcl/elasticsearch-analysis-ik
```

11.1.2 分词器安装

```
cd /usr/share/elasticsearch/bin
./elasticsearch-plugin install https://github.com/medcl/elasticsearch-analysis-ik/releases/download/v6.4.2/elasticsearch-analysis-ik-6.4.2.zip
```

11.1.3 分词器测试

创建索引

```
curl -XPUT http://192.168.47.75:9200/index
```

创建映射

```
curl -XPOST http://192.168.47.75:9200/index/fulltext/_mapping -H 'Content-Type:application/json' -d'
{
        "properties": {
            "content": {
                "type": "text",
                "analyzer": "ik_max_word",
                "search_analyzer": "ik_max_word"
            }
        }

}'
```

创建一些文档

```
curl -XPOST http:// 192.168.47.75:9200/index/fulltext/1 -H 'Content-Type:application/json' -d'
```

```
{"content":"美国留给伊拉克的是个烂摊子吗"}
'
curl -XPOST http:// 192.168.47.75:9200/index/fulltext/2 -H 'Content-Type:application/json' -d'
{"content":"公安部：各地校车将享最高路权"}
'
curl -XPOST http:// 192.168.47.75:9200/index/fulltext/3 -H 'Content-Type:application/json' -d'
{"content":"中韩渔警冲突调查：韩警平均每天扣 1 艘中国渔船"}
'
curl -XPOST http://192.168.47.75:9200/index/fulltext/4 -H 'Content-Type:application/json' -d'
{"content":"中国驻洛杉矶领事馆遭亚裔男子枪击 嫌犯已自首"}
'
```

查询

```
curl -XPOST http:// 192.168.47.75:9200/index/fulltext/_search?pretty  -H 'Content-
Type:application/json' -d'
{
    "query" : { "match" : { "content" : "中国" }},
    "highlight" : {
        "pre_tags" : ["<tag1>", "<tag2>"],
        "post_tags" : ["</tag1>", "</tag2>"],
        "fields" : {
            "content" : {}
        }
    }
}
'
```

11.1.4 更新字典

11.2 日志收集展示

11.2.1 架构图

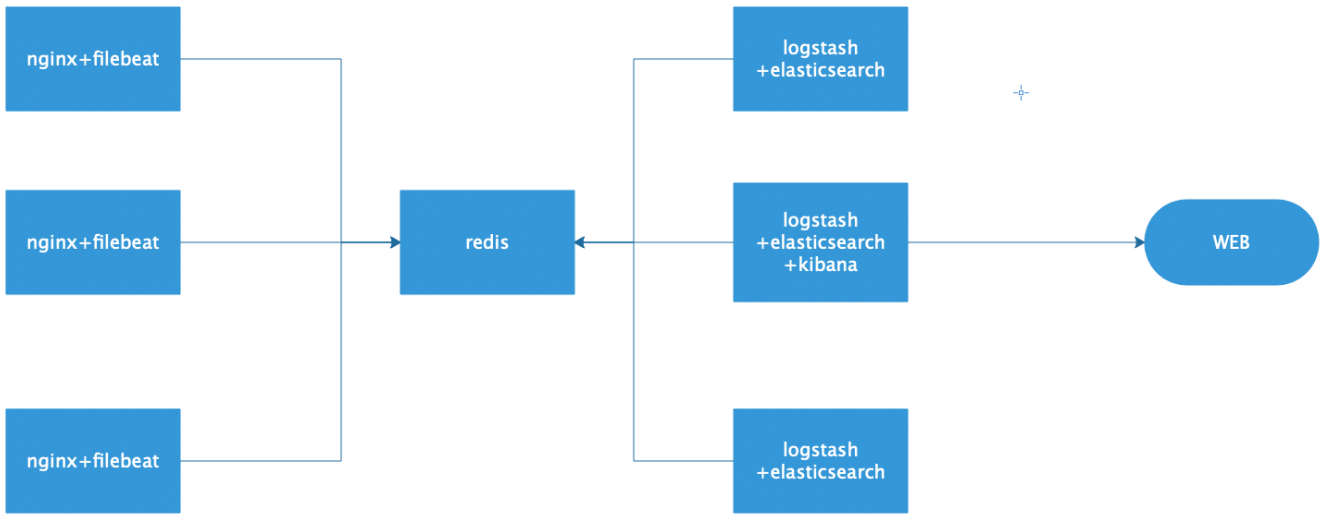

11.2.2 nginx 修改日志格式

```
log_format access_json '{"@timestamp":"$time_iso8601",'
        '"host":"$server_addr",'
        '"clientip":"$remote_addr",'
        '"size":$body_bytes_sent,'
        '"responsetime":$request_time,'
        '"upstreamtime":"$upstream_response_time",'
        '"upstreamhost":"$upstream_addr",'
        '"http_host":"$host",'
        '"url":"$uri",'
        '"domain":"$host",'
        '"xff":"$http_x_forwarded_for",'
        '"referer":"$http_referer",'
        '"status":"$status"}';
```

11.2.3 redis 配置

```
### 以守护进程模式启动
daemonize yes

### 绑定的主机地址
bind 192.168.47.75
```

```
### 监听端口
port 6380

### pid 文件和 log 文件的保存地址
pidfile /opt/redis_cluster/redis_6380/pid/redis_6380.pid
logfile /opt/redis_cluster/redis_6380/logs/redis_6380.log

### 设置数据库的数量，默认数据库为 0
databases 16

### 指定本地持久化文件的文件名,默认是 dump.rdb
dbfilename redis_6380.rdb

### 本地数据库的目录
dir /data/redis_cluster/redis_6380
```

11.2.4 filebeat 配置

```
filebeat.prospectors:
- type: log
  enabled: true
  paths:
    - /usr/local/nginx/logs/*access.log
  json.keys_under_root: true
  json.overwrite_keys: true

output.redis:
    hosts: ["192.168.47.75"]
    key: "filebeat"
    db: 0
    timeout: 5
```

11.2.5 logstash 配置

```
root@docker-elk-135:~/docker_compose# cat logstash.conf
input {
  redis {
    host => "192.168.47.75"
    port => "6380"
    db => "0"
```

```
    key => "filebeat"
    data_type => "list"
  }
}

filter {
  mutate {
    convert => ["upstream_time", "float"]
    convert => ["request_time", "float"]
  }
}

output {
  if [source] == "/usr/local/nginx/logs/act.goumin.com_access.log" {
    elasticsearch {
      hosts => "http://192.168.47.75:9200"
      manage_template => false
      index => "act-%{+YYYY.MM}"
    }
  }


  if [source] == "/usr/local/nginx/logs/app.goumin.com_access.log" {
    elasticsearch {
      hosts => "http:// 192.168.47.75:9200"
      manage_template => false
      index => "app-%{+YYYY.MM}"
    }
  }
```

11.2.6 redis 验证数据

```
keys *
LLEN filebeat
RPOP filebeat
```

11.3 提取 es 存储的日志 IP 并添加防火墙

11.3.1 架构图

11.3.2 功能实现

1.提取录入到 es 里 nginx 日志中的一定时间内的所有域名的访问 IP 最大的前 10 个

2.过滤后提取结果保存到文本中

3.判断提取的 IP 是否白名单里的爬虫

4.如果不是就添加到 iptables 防火墙里，每 1 小时恢复防火墙一次

5.将封禁结果通过邮件发送给运维

11.3.3 脚本解读

```
mysql-76:~/elk_ip# tree -L 2
.
├── ip_log
│   ├── act.log
│   ├── ask.log
│   ├── att.log
│   ├── bbs.log
│   ├── c.log
│   ├── dog.log
│   ├── i.log
│   ├── mall.log
│   ├── m.log
│   ├── www.log
│   └── zhidao.log
├── iptables_log
├── mail_log
│   ├── all_ip.txt
│   ├── mail_all.txt
│   ├── mail_log.txt
│   └── mail_status.txt
├── scripts
│   ├── disable_ip.sh
│   ├── elk_topip.sh
│   ├── mail.sh
│   └── url_list.txt
└── spider_log
```

提取 IP 脚本内容

```
mysql-76:~/elk_ip/scripts# cat elk_topip.sh
#!/bin/bash
```

```
###脚本说明###
#脚本功能:从 elasticsearch 提取 10 分钟内访问 IP 次数最多的 IP，然后存入日志中

begin_time="$[$(date -d "-10 min" +%s)*1000]"
end_time="$[$(date +%s)*1000]"

url_date=$(date +%Y.%m)


for url in $(cat /root/elk_ip/scripts/url_list.txt)
do
   curl -s -XPOST http://192.168.47.135:19200/${url}-${url_date}/_search?pretty -H 'Content-Type:
application/json'    -d
'{"size":0,"_source":{"excludes":[]},"aggs":{"2":{"terms":{"field":"remote_addr.keyword","size":10,"order":{"_
count":"desc"}}}},"stored_fields":["*"],"script_fields":{},"docvalue_fields":["@timestamp"],"query":{"bool":{"
must":[{"match_all":{}},{"range":{"@timestamp":{"gte":'"${begin_time}"',"lte":'"${end_time}"',"format":"epo
ch_millis"}}}],"filter":[],"should":[],"must_not":[{"match_phrase":{"host.name":{"query":"lingdang-
196"}}},{"match_phrase":{"remote_addr.keyword":{"query":"119.61.26.157"}}}]}}}'|egrep
"key|\"doc_count\""|xargs -n 6|awk -F"[ ,]" '{print $3":"$7}'|egrep -v
"192.168.5|210.14.154" >/root/elk_ip/ip_log/${url}.log
done
```

封锁脚本

```
mysql-76:~/elk_ip/scripts# cat disable_ip.sh
#!/bin/bash

###脚本说明###
#当提取 IP 的脚本执行完毕后，此脚本进行筛选和过滤
#如果 IP 访问不足 100 次，过滤
#如果来自 196，过滤
#如果是爬虫，过滤
#其他情况加入加入防火墙阻止列表并调用发送邮件脚本发送邮件

time=$(date +%F-%H:%M)
mkdir -p /root/elk_ip/iptables_log/${time}
mkdir -p /root/elk_ip/spider_log/${time}
path_mail_log=/root/elk_ip/mail_log/mail_log.txt
path_mail_all=/root/elk_ip/mail_log/mail_all.txt
path_mail_status=/root/elk_ip/mail_log/mail_status.txt
```

```
>${path_mail_log}

for url in $(cat /root/elk_ip/scripts/url_list.txt)
do
   path_ip_log="/root/elk_ip/ip_log/${url}.log"
   path_iptables_log="/root/elk_ip/iptables_log/${time}/${url}.log"
   path_spider_log="/root/elk_ip/spider_log/${time}/${url}.log"
   for i in $(cat ${path_ip_log})
   do
       ip=$(echo ${i}|sed -rn 's/(.*):(.*)/\1/p')
       num=$(echo ${i}|sed -rn 's/(.*):(.*)/\2/p')
       if [ "${num}" -gt "100" ]
       then
           cmd=$(/usr/bin/host ${ip}|egrep 'not found|no servers'|wc -l)
           if [ "${cmd}" == 1 ]
           then
             if [ "$(/sbin/iptables -nL|grep "${ip}"|wc -l)" == "0" ]
             then
                     /sbin/iptables -I INPUT 6 -s ${ip} -j DROP
                     echo "$(date +%F-%H:%M) ${num}:${ip}" >> ${path_iptables_log}
                     /bin/bash /root/elk_ip/scripts/mail.sh ${url} ${ip} ${num} ${time} >> ${path_mail_log}
             else
                     echo "already exists $(date +%F-%H:%M) ${num}:${ip}" >> ${path_iptables_log}
             fi
           else
             echo "$(date +%F-%H:%M) ${num}:${ip}" >> ${path_spider_log}
             echo "$(/usr/bin/host ${ip})" >> ${path_spider_log}
           fi
       fi
   done
done

if [ -s ${path_mail_log} ]
then
     cat ${path_mail_log} >> ${path_mail_all}
     cat ${path_mail_log}|mail -s 查封 IP 信息 zhangya@goumin.com,wangwangqi@goumin.com >>
${path_mail_status} 2>&1
fi
```

邮件脚本

```
mysql-76:~/elk_ip/scripts# cat mail.sh
#!/bin/bash
echo -e "
访问域名: $1
访问 IP：$2
访问次数:$3
访问时间:$4
处理结果:添加防火墙成功
==========================
"
```

第12章 故障分享

12.1 滚动升级关闭自动分片导致的故障

12.2 内存分配不足导致 GC 问题