

2018 CONTAINER DAY

基于Rancher的ELKstack as a Service实践

姜江 | 新东方信管部高级系统工程师



2018 CONTAINER DAY

1. ELK Stack的生态圈

ELK生态圈：BELKX + kafka + fluentd



Beats

数据收集



elasticsearch

索引和存储



Logstash

数据聚集
和处理



Kibana

分析和可
视化



X-Pack

监控权限
高级功能



Fluentd

数据收集、
聚集和处
理



Kafka

高吞吐流
处理平台


核心组件elasticsearch

- Elastic Stack 的核心
- Elasticsearch 是一个分布式的 RESTful 风格的搜索和数据分析引擎
- 据说是为了解决搜索菜谱的需求而诞生




elasticsearch

ElasticSearch基本要素






- Cluster (集群)
- Node (节点)
- Shard (分片)
- Replicas (分片副本)
- Index (索引)
- Type (类型)
- Documents (文档)

Cluster、Node、Shard和Index



分片、副本与集群健康程度

GET /_cluster/health




所有主要分片和复制分片都可用

所有主要分片可用，但不是所有复制分片都可用

不是所有的主要分片都可用

文档写入ES的过程

$shard = hash(document_id) \% (num_of_primary_shards)$



简单总结


ES特性

- 根据文档ID和分片数量取余得到文档的目标分片位置
- ES集群根据分片位置将文档路由到对应的node上处理
- 收到文档的shard保存日志，并交由lucene处理，处理后刷入OS的Buffer中，最后按条件刷入磁盘形成segment

优化建议

- 增减集群中的data node 会引起数据的再分配，可以通过参数控制一次再分配的索引数量
- 增加coordinating node 作为数据读取的负载均衡，他会直接将请求路由掉对应的data node
- ES的内存分配遵循50%原则

ELK生态圈：常见架构



2018 CONTAINER DAY

2. 容器化ELK云服务的优势

传统方式搭建ELK



- 按项目申请环境和资源
- 买来五台，十台的高配服务器
- 每台机器做为一个node，配置相同的cpu、内存、SSD
- 只创建一个集群应付所有的业务场景
- 按照项目将所有数据都塞进去
- 撑不住了就按照上面步骤再搭一套集群，周而复始

ELK云服务的优势



- 资源集中分配，避免资源竖井
- 基础架构代码化，标准化
- 按照应用场景，数据可靠性、服务SLA区分ES集群
- 相同类型的数据放在一个集群内，而不是按照项目分配集群
- 按照组件的不同负载特性组合资源
- 自动化部署/回收实例降低运维压力

按场景分割ES集群实例




日志分析

量大，存储时间长，数据完整性要求适中



流量分析


数据量巨大，存储时间短，数据完整性要求高



搜索查询加速

数据适中，存储时间长，数据完整性要求高

按特性整合计算资源



- 较高配置的服务器替代低配服务器，提高服务器密度。
- 将不同特性的计算负载交叉整合到一台物理服务器上，如：
 - 计算密集负载
 - 内存密集负载
 - I/O密集负载
 - 存储量密集负载
- 避免资源的闲置。

2018 CONTAINER DAY

3.新东方ELK云服务实践

新东方 ELK 云服务路线图

目前在这里



RANCHER
2018
CONTAINER
DAY

原型阶段
Rancher1.6
Cattle
Host Storage

V1.0阶段
Kubernetes
ELK X-Pack
Rancher 2.0
CEPH 存储/
Rook.io

V2.0阶段
K8s Operator
自研门户
开源ELK
自研大数据
能力

服务清单

日志分析 公共服务

- 基于ELK6.X白金商业版
- Hot/Warm数据分级架构
- 提供机器学习和Graph分析功能
- 对接日志和流量类数据

数据搜索 公共服务

- 基于ELK6.X 黄金商业版
- 索引级别的隔离
- 较高的安全设置
- 索引副本配置不低于2副本
- 对接数据查询加速，搜索类数据

其他 专有服务

- 满足项目特殊要求或历史遗留项目
- 基于ELK 5.X/6.X开源版
- Nginx简单认证
- 多集群复用硬件资源

硬件设计



RANCHER
2018
CONTAINER
DAY

- 通用X86服务器
- $\geq 2 \times 16$ core CPU
- 256G~512G内存
- 2 X SSD Raid1 操作系统
- N X SSD Raid0
- N X SAS 旋转磁盘 Raid0
- 双万兆网卡和电源
- Centos7.4 / Ubuntu 1604
- 数据磁盘无LVM, ext4fs
- 设置Swappiness, vm.max_map_count, nproc等等

编排引擎和组件


Rancher 1.6 + Cattle

- 镜像docker.elastic.co白金/黄金/OSS
- Docker 17.06.2-ce
- 自定义Rancher catalog
- Rancher vxlan
- Rancher cron
- Bind mount volume


Rancher 2.0 + K8S

- 镜像docker.elastic.co白金/黄金/OSS
- Docker 17.03.2-ce
- K8S 1.10
- 自定义的Helm
- Statefulset/deployment/configmap/secret/cronjob
- StorageClass
- Ceph


部署方案（初始）



部署方案（最终）



Hot/Warm/Cold架构



Hot-Warm Data Node

Stack: -sec-1

Add Service

Up to date

Active

Active	es-client + 2 Sidekicks	Service	3 Containers
Active	es-data + 2 Sidekicks	Service	15 Containers
Active	es-data-w + 2 Sidekicks		
Active	es-kibana		

Name	Status	CPU Usage	CPU Throttling	JVM Memory	Disk Free Space	Shards
sec-1-es-client-1	Online	N/A	0 ns	62 %	125.7 GB	0
sec-1-es-data-1	Online	N/A	0 ns	26 %	31.4 GB	28
sec-1-es-data-2	Online	N/A	0 ns	46 %	39.4 GB	34
sec-1-es-data-3	Online	N/A	0 ns	18 %	60.4 GB	25
sec-1-es-data-4	Online	N/A	0 ns	62 %	93.2 GB	72
sec-1-es-data-5	Online	N/A	0 ns	50 %	44.1 GB	78
sec-1-es-data-w-1	Online	N/A	0 ns	44 %	68.0 GB	67
sec-1-es-data-w-2	Online	N/A	0 ns	38 %	132.7 GB	15
sec-1-es-data-w-3	Online	N/A	0 ns	31 %	115.4 GB	10
sec-1-es-data-w-4	Online	N/A	0 ns	40 %	132.7 GB	12
sec-1-es-data-w-5	Online	N/A	0 ns	18 %	132.8 GB	11


容器的编排举例 (cattle)




RANCHER
2018
CONTAINER
DAY

- 一个容器内存上限为64G内存
- 假设一台256G内存的物理机可以被分为五个部分或者更多：
 - 3 X 64G的标准容器
 - 32G内存用于跑低内存消耗的容器，如：master node, ml node, zookeeper, logstash, kibanna,
 - 剩下的32G留给宿主机和环境容器，如网络组件、自动作业、cadvsior, cronjob container, node exporter、fluentd等
- 其中标准容器用于跑以下三类容器：
 - Ingest node
 - Hot data node /Kafka broker (SSD)
 - Warm data node (SAS)
- 全部容器运行在Rancher vxlan网络上
- CPU按照比例分配，限制最大可用的share



容器的编排举例



容器的编排(K8s)草案



运维：前后台运维界面



运维：容器化运维

Catalog: Library



Rancher Container Cron

Rancher Container Crontab starts, stops or restarts containers

Already Deployed

Stack: curator-sec

Started-Once

forcemerge-

Image: c

Service

1 Container

Started-Once

forcemerge-

Image: c

Service

1 Container

Started-Once

forcemerge-

Image: c

Service

1 Container

Started-Once

index-hw-i

Image: c

Service

1 Container

Started-Once

index-h

Image: c

Service

1 Container

Started-Once

index-h

Image: c

Service

1 Container

Started-Once

index-h

Image: c

Service

1 Container

Started-Once

index-h

Image: c

Service

1 Container

Service: index-hw-docker

in curator-sec

Type: Service

Scale: 1

Image: /pub/docker-curator-cli:5.5.1

Entrypoint: None

Command: --host http://:9200 -- --loglevel INFO allocation - -key box_type --value warm --allocation_type require --filter_list [{"filtertype": "age", "source": "creation_date", "direction": "older", "unit": "days", "unit_count": 31}, {"filtertype": "pattern", "kind": "prefix", "value": "docker"}]

Ports

Containers

Labels

Log

State	Name	IP Address	Host	Image
Started-Once	curator-sec-		host15	pub/docker-cur...

运维：容器化组件的配置管理

Stack: fluentd

4 部署到所有主机

2 GIT提交

3 Rancher Pipeline 自动构建

1 保存

0 fluent配置更新

名称	修改日期	类型	大小
20180324.Dockerfile	2018/3/24 18:28	DOCKERFILE 文件	1 KB
Dockerfile	2018/6/6 17:13	文件	1 KB
dockerfluent.conf	2018/6/6 18:28	CONF 文件	2 KB

```
type tail
read_from_head true
path /var/lib/docker/containers/*/*-json.log
pos_file /fluentd/fluentd-docker.pos
time_format %Y-%m-%dT%H:%M:%S
tag docker.*
format json
</source>

<filter docker.var.lib.docker.containers.*.log>
type record_transformer
<record>
```

1/4配测试环境举例

Stack: elasticsearch-sec-1

Active	es-client + 2 Sidekicks ⓘ
Active	es-coo + 2 Sidekicks ⓘ
Active	es-data + 2 Sidekicks ⓘ
Active	es-data-w + 2 Sidekicks ⓘ
Active	es-kibana ⓘ
Active	es-kibana-lb ⓘ
Active	es-logstash ⓘ
Active	es-logstash-syslog ⓘ
Active	es-master + 2 Sidekicks ⓘ
Active	es-ml + 2 Sidekicks ⓘ
Inactive	logstash-oss ⓘ
Active	sec-client-lb ⓘ
Active	sec-coo-lb ⓘ

Elasticsearch Health is green

Overview

Version	6.2.3
Uptime	a day
Jobs	2

Nodes: 19

Disk Available	63.14% 2TB / 4TB
JVM Heap	29.16% 35GB / 119GB

Indices: 476

Documents	906,570,978
Disk Usage	1TB
Primary Shards	2,710
Replica Shards	2,718

Kibana Health is green

Overview

Requests	28579
Max. Response Time	13929 ms

Instances: 2

Connections	2,650
Memory Usage	14.36% 411MB / 3GB

Logstash

Overview

Events Received	12.6m
Events Emitted	12.6m

Nodes: 4

Uptime	a day
JVM Heap	33.21% 1GB / 4GB

Pipelines: 2


2018 CONTAINER DAY

4. 实践中遇到的坑

ES内存分配5/5原则

32G for
JVM

32G for
OS buffer
& cache




为什么 Jvm Heap <=32G ? Jvm Oop

<http://java-performance.info/over-32g-heap-java/>

```
1 public class Mem32Test {
2     public static void main(String[] args) {
3         List<Integer> lst = new LinkedList<>();
4         int i = 0;
5         while ( true )
6         {
7             lst.add( new Integer( i++ ) );
8             if ( ( i & 0xFFFF ) == 0 )
9                 System.out.println( i ); //shows where you are 😊
10            if ( i == System.currentTimeMillis() )
11                break; //otherwise will not compile
12        }
13        System.out.println( lst.size() ); //needed to avoid dead code optimizat
14    }
}
```

RANCHER
2018
CONTAINER
DAY

JVM OVER 32GB LINKEDLIST LENS



滚动操作

- 一个节点操作完成后休息适当时间，随后继续下一个节点的操作，以避免数据丢失
- cattle中升级service时注意设置间隔时间
- 幸运的是：滚动升级是Rancher Cattle 升级服务的默认行为
- K8S中data node 使用 statefulset，默认按顺序滚动操作，其他node可以直接使用deployment

Shards设置

- 每个node小于1000个Shards
- Shards size < 单个Data Node的JVM size
- Shards 并非越多越好，取决于数据量

副本设置

- 至少设置1副本
- 重复一遍至少1副本
- 搜索、查询加速类推荐2副本

混合负载注意事项

- 容器必须开启资源隔离
- 相同集群的data node 不允许跑在相同的Host上
- 按照不征用资源原则混合负载，比如计算类与存储类混合等。
- 征用同类资源负载尽量不混合。比如logstash 和 ml node
- 始终在宿主机上保留一点空余资源。

Rancher Cattle 编排的坑

- 任何编排引擎都不知道你跑的负载有什么特性，除非你让他知道
- Cattle 编排算法是按节点上容器最少原则调度容器，而不关心CPU、内存消耗情况！在cattle不断尝试调度的过程中可能引发“调度雪崩”
- 用Label限定调度，而不能将调度完全交给Cattle

2018
CONTAINER DAY

THANK YOU !

姜江 | 新东方信管部

