

苏宁ES平台化实践之路

苏宁大数据平台.搜索平台组 韩宝君
2018年6月



苏宁易购
suning.com

造极2018
ULTIMATE CREATION

苏宁云商IT总部 大数据平台研发中心

大数据平台职责：

提供苏宁集团各个业务所需要的大数据
存储和计算能力。

保证平台的稳定、高效运行。

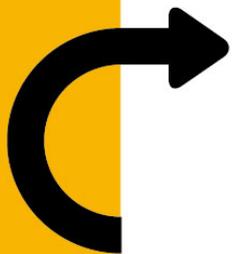
提高平台易用性。



个人职责：

Elasticsearch组件负责人



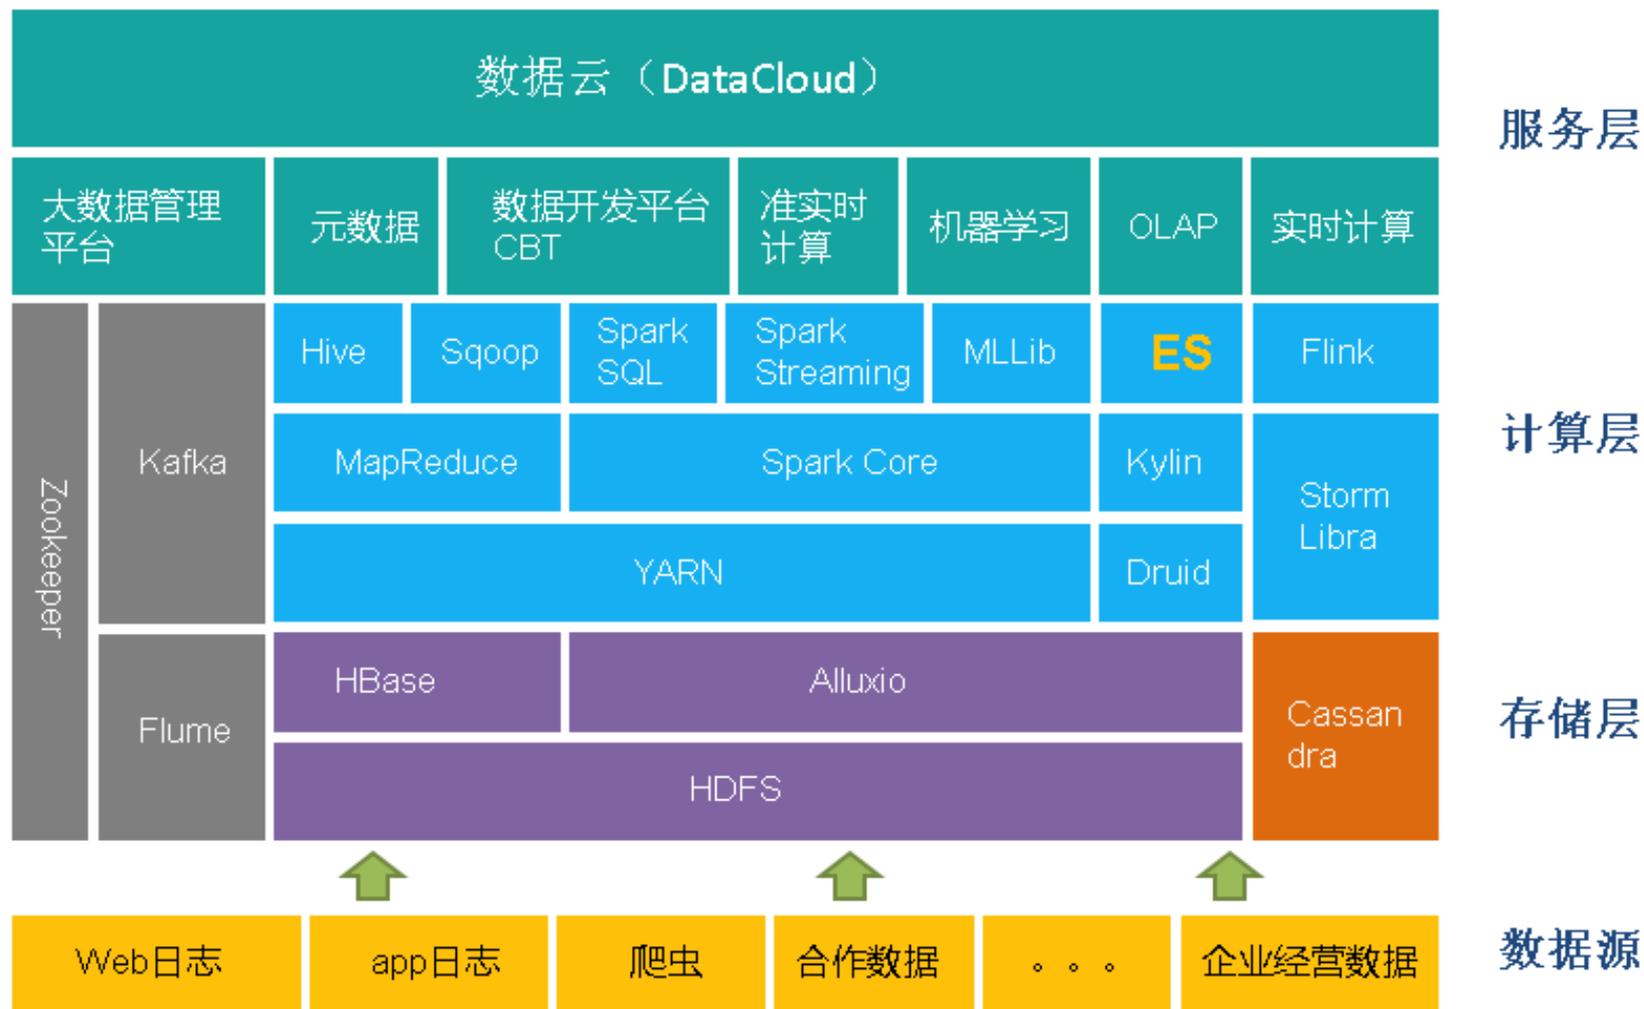


1.ES平台总体介绍

2.ES平台化之路

3.实战经验

苏宁大数据平台总体架构



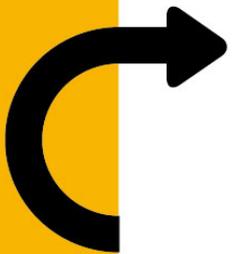
Elasticsearch平台概况

集群规模

18个集群，195个节点
接入100+个业务，4500+个索引
数据量64+TB

平台功能

独占服务/共享服务：资源利用率和业务隔离的权衡
计量计费：强调成本概念
页面化服务：使用便利性，减少误操作，节约时间



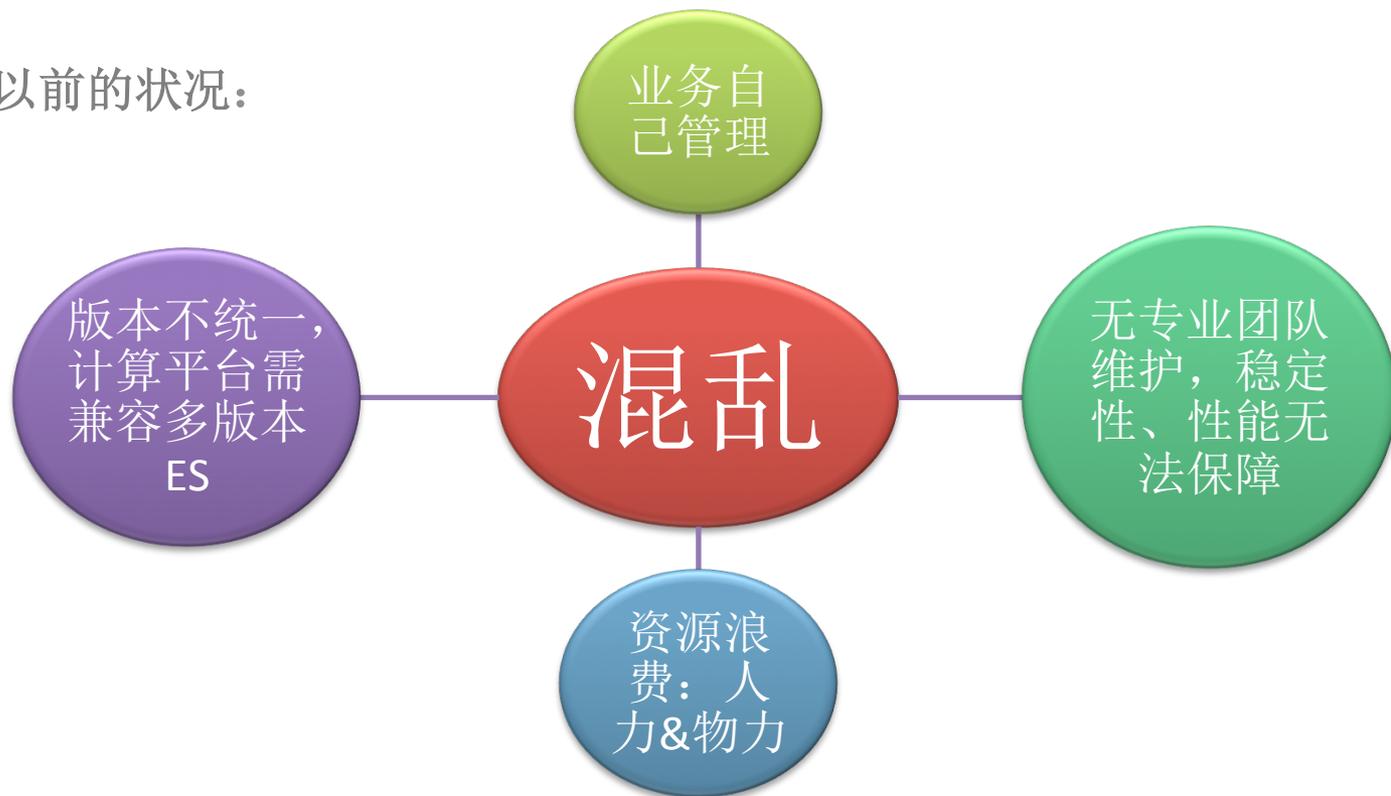
1.ES平台总体介绍

2.ES平台化之路

3.实战经验

为什么做ES平台？

一年以前的状况：



目标：做一个专业的ES平台

人肉部署集群
人肉对接业务
人肉运维集群

自动化部署集群
申请服务页面化
计量计费功能
可用性、性能监控
安全增强
数据探查

纯人肉时代

真正的平台化服务

人肉阶段的对接文档

ES 业务对接

·1、业务信息

一级中心	部门名称	业务对接人	工号

·2、项目信息

项目名称	
项目英文简称	
项目介绍	

·3、应用场景

使用方式	<input type="checkbox"/> 实时入库 <input type="checkbox"/> 离线入库 <input type="checkbox"/> 结构化查询 <input type="checkbox"/> 排序 <input type="checkbox"/> 全文搜索 <input type="checkbox"/> 聚合计算 <input type="checkbox"/> 高维数据查询 <input type="checkbox"/> 导出
场景描述	

·4、数据量级

数据量级	每天新增数据数量	每天新增数据大小	大促每天新增数据数量	大促每天新增数据大小
	初始化数据数量	初始化数据大小	保存时间	搜索 QPS
	实时入库 TPS	批量入库间隔	承受搜索延时范围	承受导出延时范围

人肉阶段的对接文档

索引(INDEX)	类型(TYPE)	字段名	数据类型	字段值	主键	备注
kbmp_knowledge	answer (子文档)	id	integer	47165		精确匹配
		sq_id	integer	13972		精确匹配
		answer	text	信用卡转入涉及资金套现问题呢，所以零钱包是不支持信用卡转入的哦，不过您可以使用借记卡转入。		全文搜索，模糊查询(IK分词)
		scene_code	keyword	10002		精确匹配，分组字段
		scene	keyword	非辅助应答		精确匹配，排序字段
		terminal_code	keyword	20001		精确匹配
		terminal	keyword	pc		不查询
		create_dttm	date	2017-10-16 17:18:11		时间区间，范围搜索，排序字段
		validity_date	date	2030-01-01		时间区间，范围搜索，
		validity_dttm	date	2030-01-01 00:00:00		时间区间，范围搜索，
is_permanent	integer	1		精确匹配，聚合字段		

监控管理： ES集群的各项监控指标展示

集群管理： 支持多集群，可以查看具体集群信息和节点列表

项目管理： 使用ES服务的项目列表，分配给各自系统的密钥

资源管理： 机器列表，该机器归属于哪些集群及部署哪些软件包

软件包管理： 支持选择的ES版本相关软件包

索引管理： 该系统下的索引列表，索引的详细信息

工单管理： 用户可以提交相应的工单，管理员审批

计量管理： 系统、集群、索引的请求量和存储量及详情

查询管理： 可以像kibana一样查询es

集群巡检 集群监控 节点监控 索引监控 线程池监控

刷新周期 15s

系统 所有系统 机房 所有机房 告警级 所有告警 集群 所有集群

别

查询



Clusters	Nodes	Indices	Memory
18	195	4554	2117GB/5138GB
Total Shards	Data	Unassigned Shards	Documents
19501	65T	394	1218亿

触发时间	解决时间	所属中心	所属部门	管理员	机房	集群名称	集群状态	集群类型	风险项	风险说明
2018-05-24T13:29:19.000Z	2018-06-29T06:16:02.000Z						red	独占	拒绝任务. 分片未分配. 部分...	拒绝任务:
2018-05-24T06:39:26.000Z	2018-06-29T06:16:02.000Z						red	独占	拒绝任务. 拒绝任务. 拒绝任务...	拒绝任务:

机器列表

+ 新增资源

机房: 机器类型: 机器标签:

机器状态: 部署软件: 部署版本:

查询

包:

主机名	节点IP	节点CPU	节点内存	节点磁盘	节点端口	归属集群	部署版本	操作
		32	131072 M	172032/data00 281600/data01 281600/data02	9100-9300		elasticsearch: 5.4.2.0	修改配置 删除
		32	131072 M	172032/data00 281600/data01 281600/data02	9100-9300		elasticsearch: 5.4.2.0	修改配置 删除
		32	131072 M	172032/data00 281600/data01 281600/data02	9100-9300		elasticsearch: 5.4.2.0	修改配置 删除
		32	131072 M	172032/data00 281600/data01 281600/data02	9100-9300		elasticsearch: 5.4.2.0	修改配置 删除

软件包管理 > 软件包列表

软件包列表

+ 新增软件包

软件包名称:

ALL

软件包版本:

ALL

机器IP:

请输入IP

查询

软件包名称	软件包版本	路径	兼容版本	部署集群	MD5	已安装节点	未安装节点	操作
elasticsearch	5.4.2.0	ftp	5		f2489rbfkr hfo4nfoi13 4			修改 部署 卸载
kibana	5.4.2	ftp	5		frwefqwerf ewrf			修改 部署 卸载
logstash	2.4.1	ftp	2		98hf0cpwn fckhd982u 3r			修改 部署

集群管理-管理员视图

集群管理

集群管理

[+创建集群](#)

[+扩容集群](#)

[+缩容集群](#)

系统名称

机房

集群类型

集群名称

软件包名称

软件包版本

查询

totalClusters

18

totalNodes

195

totalIndices

4554

totalShards

19501

totalDocs

1219亿

totalStore

65T

集群名称	机房	系统名称	集群端口	新增数据条数	新增数据大小	TPS	QPS	状态	白名单	黑名单	操作	删除集群
				0	0	实时:0/离线: 0	0	运行	添加白名单	添加黑名单	<input checked="" type="checkbox"/>	
				0	0	实时:0/离线: 0	0	运行	添加白名单	添加黑名单	<input checked="" type="checkbox"/>	

集群管理-用户视图

集群管理

集群管理

[+申请集群](#)

[↩申请扩容](#)

[+申请缩容](#)

机房

ALL

集群类型

ALL

集群名称

ALL

软件包名称

ALL

软件包版本

ALL

查询

totalClusters	totalNodes	totalIndices	totalShards	totalDocs	totalStore
1	20	181	2032	155亿	15T

集群名称	机房	系统名称	集群端口	新增数据条数	新增数据大小	TPS	QPS	状态	白名单	黑名单
				0	0	实时:0/离线: 0	0	运行	添加白名单	添加黑名单

共 1 条

20条/页

<

1

>

前往

1

页

工单管理-待审批

工单管理

工单管理

系统名称: 工单类型: 申请人工号:

查询

待审批

申请记录

已处理

序号	工单名称	工单类型	系统	申请人	申请时间	上线时间	操作
1		新增字段			2018-06-29 14:34:51	2018-07-03 00:00:00	审批 撤销
2		创建索引			2018-06-29 14:30:11	2018-07-03 00:00:00	审批 撤销

工单管理

工单管理

系统名称: ALL

工单类型: ALL

申请人工号: 请输入工号

查询

待审批

申请记录

已处理

序号	工单名称	工单类型	申请系统	申请人	审批人	处理时间	审批结果	操作
1		创建索引			韩宝君	2018-06-28 19:18:54	通过	查看
2		新增字段			韩宝君	2018-06-28 18:38:54	通过	查看
3		新增字段			韩宝君	2018-06-28 17:59:30	不通过	查看

索引管理

索引管理

[+ 申请索引](#) [📄 申请实时入库](#) [📄 申请离线入库](#) [📄 申请新增字段](#) [📄 申请删除索引](#)

系统: 机房: 集群:

索引: [查询](#)

索引名称	索引类型	系统名称	机房	集群名称	上线时间	保存天数	删除字段	操作
cdss	tdm_sn_theme_content_d				2018-06-28T16:00:00.000Z	700	id	查看 删除
clm	bs_tracking_log				2018-06-10T16:00:00.000Z	1000	callTime	查看 删除
ddposorderinfo	orders				2018-05-31T16:00:00.000Z	99999	isDelete	查看 删除

申请新建索引

* 集群名:

* 索引名:

* 类型名:

* 上线时间:

* 保存天数:

* 删除字段:

索引主键:

* 申请原因:

* 索引mapping:

申请配额:

* 每天新增数据数量:

* 初始化数据数量:

* 实时TPS:

* 每天新增数据大小:

* 初始化数据大小(M):

* 离线TPS:

(M):

* 集群QPS:

确定

取消

计量管理—计量概览

计量概览

所属系统: 所属集群:

最近三个月总请求量

6月: 126,70502
5月: 0
4月: 0

最近三个月读请求量

6月: 7,3965
5月: 0
4月: 0

最近三个月写请求量

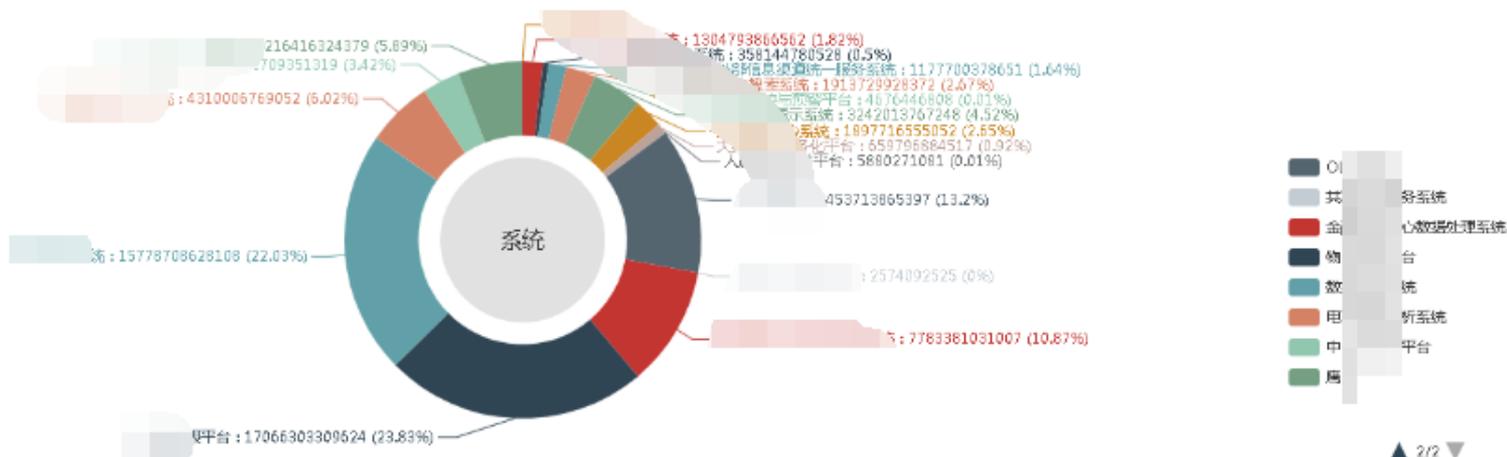
6月: 12,6537
5月: 0
4月: 0

占比分布

占比对象: 系统 集群

统计维度: 存储量 读请求量 写请求量

(默认显示前十名)



计量管理 > 计量管理

计量明细

选择系统: 不限

选择集群: 所有

起止时间: 开始日期 - 结束日期

查询

清空

	所属系统	集群名称	存储量	读请求量	写请求量	操作
√			126595191	14356	14690	
			3126595191	4356	14690	详情
>			4149263369	87	551890	
>			690306399	526	33842	
>			743996782	2307	333017	
>			295276332	747157	384098	
>			492492770	33485	7828	

计量管理 > 计量明细 > 计量详情

计量详情

返回

选择索引:

查询

清空

索引	存储量	读请求量	写请求量
ssa2_abnormally_log_20180617	4397218	8	680425
ssa2_abnormally_log_20180618	6039480	6	174596
ssa2_abnormally_log_20180619	1146687	3	88346
ssa2_abnormally_log_20180620	71263400	3	22806
ssa2_abnormally_log_20180621	2948190	0	37600
ssa2_abnormally_log_20180622	76822381		0173
ssa2_abnormally_log_20180623	46063794		35144

项目管理 > 项目概览

项目概览

系统: 所有系统

查询

系统全称	系统帐号	技术总监	系统管理员	所属中心	创建时间	集群名称
					2018-05-24T01:47:09.000Z	
					2018-05-24T01:47:09.000Z	
					2018-05-24T01:47:09.000Z	
					2018-05-24T01:47:11.000Z	
					2018-05-24T01:47:09.000Z	

项目管理 > 密钥管理

密钥管理

+ 新增密钥

系统: 所有系统

查询

+ 全部展开

系统ID	系统名称	密钥ID	发送邮箱	操作
▼				系统删除
		AK:oRuH7PRLQZSBTZcQ UiGYUg SK:xyArxC4SRSCYMSCum hiLDQ		密钥发送 密钥删除
		AK:xAIVQWuJQzKLMpx_2 0Wi4Q SK:MQ6XpoyITZ6inYTZRJ GIYQ		密钥发送 密钥删除

查询管理

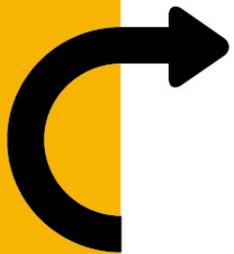
权限：用户只有查看权限、不能修改、删除

查询管理

所属系统: 所属集群:

```
GET mnos/_search
{
  "query": {
    "match_all": {}
  }
}
```

```
{
  "took": 2,
  "timed_out": false,
  "_shards": {
    "total": 5,
    "successful": 5,
    "failed": 0
  },
  "hits": {
    "total": 7,
    "max_score": 1,
    "hits": [
      {
        "_index": "mnos",
        "_type": "order",
        "_id": "2",
        "_score": 1,
        "_source": {
          "tid": "2",
          "name": "two"
        }
      },
      {
        "_index": "mnos",
        "_type": "sub_order",
        "_id": "sub_2"
      }
    ]
  }
}
```



- 1.ES平台总体介绍
- 2.ES平台化之路
- 3.实战经验

HTTP请求过长

背景:

Caused by: org.elasticsearch.hadoop.rest.EsHadoopInvalidRequest: An HTTP line is larger than 4096 bytes. (该错误表示http请求超过了es的http请求长度限制)

一个简单的macth_all查询报如上错

方案:

修改elasticsearch-hadoop源码

1. <https://github.com/hanbj/elasticsearch-hadoop.git> (hanbj_v5.4.2)
2. **Commits:** [An HTTP line is larger than 4096 bytes](#)

详情见PR: <https://github.com/elastic/elasticsearch-hadoop/pull/1154>

ThreadContextStruct:putHeaders

背景:

线程池模块在处理header时有一小问题

方案:

修改elasticsearch源码

详情见PR: <https://github.com/elastic/elasticsearch/pull/26068>

elasticsearch-hadoop build sql to dsl

背景:

创建一个Hive外部表指向ES中的某个索引，通过Hive HQL直接操作ES。当运行下面的HQL时，发现找不到数据。

```
select * from table_name where city_code in ('010', '791');
```

但是下面两条Hql都可以找到数据:

```
select * from table_name where city_code in ('010');
```

```
select * from table_name where city_code in ('791');
```

方案:

修改elasticsearch-hadoop源码

1. <https://github.com/hanbj/elasticsearch-hadoop.git> (hanbj_v5.4.2)
2. **Commits:** [change match to terms](#)

详情见PR: <https://github.com/elastic/elasticsearch-hadoop/pull/1168>

SparkSession conf

背景:

Spark2.x之后，SparkConf是全局的配置，一个系统中可以有多个SparkSession实例，而且每个SparkSession实例可以有自己单独的配置，OLAP系统中有很多个业务，每个业务有多个模型，每个模型对应多个索引（每天一个索引），每个模型对应一个SparkSession实例缓存在内存里，当要查询一个模型时，从内存里找出对应的SparkSession实例去查找对应的索引。

方案:

1. 修改elasticsearch-hadoop源码
 1. <https://github.com/hanbj/elasticsearch-hadoop.git> (hanbj_v5.4.2)
 2. **Commits:** [check cluster name and add SparkSession conf](#)

详情见PR: <https://github.com/elastic/elasticsearch-hadoop/pull/1135>

```
def main(args: Array[String]): Unit = {  
    val sparkConf = new SparkConf().setAppName("HiveToES").setMaster("local[*]")  
    sparkConf.set("spark.sql.hive.metastorePartitionPruning", "false")  
    sparkConf.set("es.index.auto.create", "true")  
    sparkConf.set("es.mapping.date.rich", "false")  
  
    val session = SparkSession.builder().config(sparkConf).getOrCreate()  
    session.conf.set("es.cluster.name", "common1")  
    session.conf.set("es.index.filter", "hanbj-20180502, hanbj-201803*")  
    session.sql(sqlText = "create table if not exists es_test using es OPTIONS (es.nodes 'localhost', es.port '9200', path 'hanbj')")  
    val dataframe = session.sql(sqlText = "select * from es_test")  
    dataframe.show()  
  
    val session1 = SparkSession.builder().config(sparkConf).getOrCreate()  
    session1.conf.set("es.cluster.name", "common2")  
    session1.conf.set("es.index.filter", "t_wh_full_link_d-2018")  
    session1.conf.set("es.nodes", "localhost")  
    session1.conf.set("es.port", "9100")  
    val df = EsSparkSQL.esDF(session1, resource = "t_wh_full_link_d")  
    df.show()  
}
```

查找大别名下的个别索引

大别名 (包含很多索引)

不同的SparkSession可以访问不同的集群或者索引

集群名

Master选举修改

背景:

当集群规模越来越大，在高并发、高基数查询和高写入量并存的场景下，节点负载高有时可能导致该节点脱离集群或者触发重新选举master，这两种情况下可能都会导致分片漂移，造成资源的浪费。

方案:

1. 部分节点单机多实例部署
2. 适量增大ping的超时时间
3. master、data、ingest节点分离（至少设置3个实例为master节点实现多可靠）
4. 修改master选举算法（master节点成为master的优先级最高，其次是ingest节点做担保）
 1. <https://github.com/hanbj/elasticsearch.git> (hanbj_v5.4.2)
 2. **Commits:** [elect master](#) , [include ingest node](#)

集群名称校验

背景:

目前有近20个ES集群，部分集群http端口一样。REST方式访问ES集群时，只要IP和端口配置正确，就可以进行访问

方案:

1. 修改elasticsearch-hadoop源码
 1. <https://github.com/hanbj/elasticsearch-hadoop.git>
(hanbj_v5.4.2)
 2. **Commits:** [check cluster name and add SparkSession conf, params append cluster.name](#)
2. 修改elasticsearch源码
 1. <https://github.com/hanbj/elasticsearch.git> (hanbj_v5.4.2)
 2. **Commits:** [RestClient add check cluster name, RestClient add check cluster name \(netty3\)](#)

访问集群方式改变成：见下页

```
RestClient client = RestClient.builder(  
    new HttpHost( hostname: "localhost", port: 9200, scheme: "http"))  
    .setClusterName("elasticsearch")  
    .build();
```

```
val sparkConf = new SparkConf().setAppName("HiveToES").setMaster("local[*]")  
sparkConf.set("es.index.auto.create", "true")  
sparkConf.set("es.cluster.name", "elasticsearch")  
sparkConf.set("es.nodes", "localhost")  
sparkConf.set("es.port", "9200")  
val sc = new SparkContext(sparkConf)
```

黑白名单控制

背景:

集群安全稳定至关重要，为了控制集群以外的机器对集群进行无效查询和攻击，所以应该支持动态允许/防止一些机器访问集群。

方案:

修改elasticsearch源码（支持IPv4、IPv6和通配符）

1. <https://github.com/hanbj/elasticsearch.git> (hanbj_v5.4.2)
2. **Commits:** [black and white list](#)
3. **参数:** 都可动态修改
 1. http.filter.enabled
 2. transport.filter.enabled
 3. http.filter.allow
 4. http.filter.deny
 5. transport.filter.allow
 6. transport.filter.deny

导出的痛

背景:

在共享集群的模式下，频繁或大并发的导出操作，会给集群造成比较大的压力，导致该集群下其他业务的正常查询延迟。

方案:

修改elasticsearch源码，添加相应的控制参数，可以控制导出的并发量和数据量。

1. <https://github.com/hanbj/elasticsearch.git> (hanbj_v5.4.2)
2. **Commits:** [limit scroll](#)
3. **参数:** 都可动态修改
 1. scroll.enabled
 2. scroll.interval
 3. scroll.concurrent.indices
 4. scroll.limit

elasticsearch-hadoop支持删除

背景:

目前的elasticsearch-hadoop版本不支持删除索引和数据，但业务有这方面的需求。

方案:

修改elasticsearch-hadoop源码，增加删除索引和根据query删除数据的逻辑。

1. <https://github.com/hanbj/elasticsearch-hadoop.git> (hanbj_v5.4.2)
2. **Commits:** [delete index and delete by query](#)

API格式统一化，标准化

背景：

delete_by_query和update_by_query API 和其他API 格式不统一，容易对业务造成困扰。

方案：

修改elasticsearch源码

1. <https://github.com/hanbj/elasticsearch.git> (hanbj_v5.4.2)
2. **Commits:** [delete by query](#), [update by query](#)

```
public void testDeleteByQuerySync() {
    client.prepareDeleteByQuery().source("hanbj") 修改后
        .filter(QueryBuilders.matchQuery("name", "hanbj")).get();
}

public void testDeleteSync() {
    DeleteByQueryAction.INSTANCE.newRequestBuilder(client) 修改前
        .filter(QueryBuilders.matchQuery("name", "hanbj")).source("hanbj").get();
}
```

请求跟踪

背景:

Transport模块有一个专用的跟踪记录器，当被激活时，记录传入和进出请求。可以使用一组通配符模式来控制哪些操作将被跟踪。默认情况下，每个请求将被跟踪，除了故障检测和ping。但是日志中并没有打印请求源，不方便进行追踪。我在ES的基础上增加了请求源IP、内部请求转发、请求发送、响应接收的详细日志。

方案:

修改elasticsearch源码，增加了请求源IP、内部请求转发、请求发送、响应接收的详细日志。

1. <https://github.com/hanbj/elasticsearch.git> (hanbj_v5.4.2)
2. **Commits:** [请求追踪](#)

元数据查看

背景:

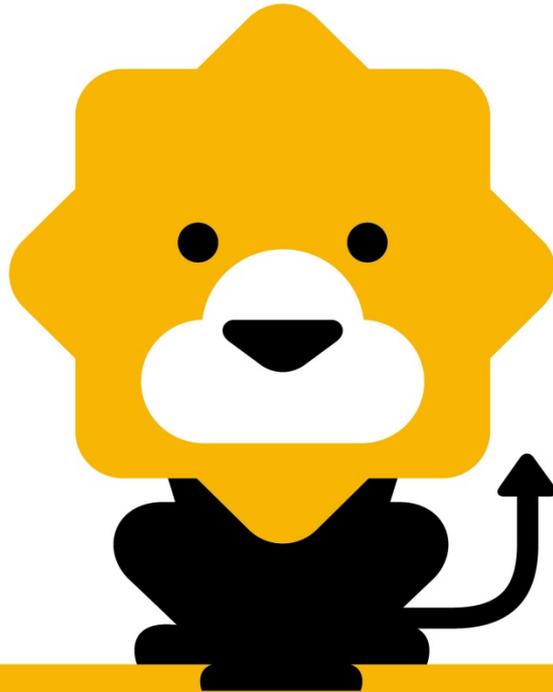
Gateway模块用于存储es集群的MetaData。MetaData每一次改变（比如增加、删除索引等），都要通过Gateway模块进行持久化。当集群第一次启动的时候，这些信息就会从Gateway模块中读出并应用。状态文件存的都是二进制，不具备可读性。

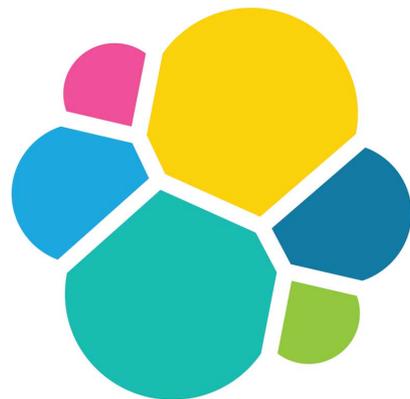
方案:

修改elasticsearch源码，实现查看所有、全局、单个索引的状态文件内容。

1. <https://github.com/hanbj/elasticsearch.git> (hanbj_v5.4.2)
2. **Commits:** [cat metadata](#)

Thanks!





elastic
中文社区

专业、垂直、纯粹的 Elastic 开源技术交流社区

<https://elasticsearch.cn/>