

## zookeeper安装以及配置HDFS和yarn的高可用

【注意】以下所有操作均在hadoop用户下，A,B,C代表3个ubuntu服务器的节点名称。

本文档默认读者已经学会使用gedit或者vim修改文件内容，所以仅描述了修改的文件以及文件内容，并未说明如何去修改。

### 1. 【A】上传zookeeper安装包

```
hadoop@mashuai01:~/Downloads$ ls
程序                               eclipse-4.7.0-linux.gtk.x86_64.tar.gz
程序.zip                          eclipse-java-2024-03-R-linux-gtk-x86_64.tar.gz
apache-maven-3.6.3-bin.zip         hadoop-3.1.3.tar.gz
apache-zookeeper-3.7.2-bin.tar.gz jdk-8u181-linux-x64.tar.gz
hadoop@mashuai01:~/Downloads$ sudo tar -zxvf apache-zookeeper-3.7.2-bin.tar.gz -C /usr/local/
[sudo] hadoop 的密码:
apache-zookeeper-3.7.2-bin/docs/
apache-zookeeper-3.7.2-bin/docs/images/
apache-zookeeper-3.7.2-bin/docs/skin/
```

### 2 【A】在hadoop用户下解压缩zookeeper到指定路径

```
1 $ sudo tar -zxvf apache-zookeeper-3.7.2-bin.tar.gz -C /usr/local/
2 $ cd /usr/local/
3 $ sudo mv apache-zookeeper-3.7.2-bin/ zookeeper
4 $ sudo chown -R hadoop:hadoop zookeeper/
5 $ cd zookeeper/conf
6 $ cp zoo_sample.cfg zoo.cfg
7 $ vim zoo.cfg
```

编辑zoo.cfg文件，修改dataDir如下图

```
# the directory where the snapshot is stored
# do not use /tmp for storage, /tmp here is for
# example sakes.
dataDir=/data/zookeeper
# the port at which the clients will connect
clientPort=2181
# the maximum number of client connections
# increase this if you need to handle more
#maxClientCnxns=60
```


zoo.cfg文件最后追加如下

```
ider
#metricsProvider.httpPort=7000
#metricsProvider.exportJvmInfo=true
server.1=mashuai01:2888:3888
server.2=mashuai02:2888:3888
server.3=mashuai03:2888:3888
```

### 3. 【A】 创建zookeeper目录以及myid文件

```
1 cd /
2 sudo mkdir data
3 sudo mkdir data/zookeeper
4 cd /data/zookeeper
5 sudo vim myid
```

编辑myid文件，写入1，如下图。



```
1 sudo chown -R hadoop:hadoop /data
```

### 4. 【B,C】 在02,03节点上，相同位置，创建相同的myid，文件内容分别2,3

```
1 cd /
2 sudo mkdir data
3 sudo mkdir data/zookeeper
4 cd /data/zookeeper
5 sudo vim myid
```

```
6
```

```
7 sudo chown -R hadoop:hadoop /data
```

编辑myid文件，B服务器myid写2，C服务器myid写3。

## 5. 【A】复制zookeeper文件到B/C上

```
1 scp -r /usr/local/zookeeper hadoop@mashuai02:/usr/local/
```

```
2 scp -r /usr/local/zookeeper hadoop@mashuai03:/usr/local/
```

## 6. 【B、C】为zookeeper目录授权

```
1 sudo chown -R hadoop:hadoop /usr/local/zookeeper
```

## 7. 【A,B,C】增加环境变量 在3台机器上

```
1 vim ~/.bashrc
```

添加如下内容

```
export ZK_HOME=/usr/local/zookeeper
```

```
export PATH=$PATH:$ZK_HOME/bin
```

```
1 source ~/.bashrc
```

## 8. 【A、B、C】启动zookeeper

```
1 zkServer.sh start
```

```
hadoop@mashuai02:/usr/local/zookeeper/bin$ ./zkServer.sh start
ZooKeeper JMX enabled by default
Using config: /usr/local/zookeeper/bin/ ../conf/zoo.cfg
Starting zookeeper ... STARTED
```

## 9. 【A、B、C】查看zookeeper各节点状态

```
1 zkServer.sh status
```

```
hadoop@mashuai01:/usr/local/zookeeper/bin$ ./zkServer.sh status
ZooKeeper JMX enabled by default
Using config: /usr/local/zookeeper/bin/ ../conf/zoo.cfg
Client port found: 2181. Client address: localhost. Client SSL: false.
Mode: follower
```

```
hadoop@mashuai02:/usr/local/zookeeper/bin$ ./zkServer.sh status
ZooKeeper JMX enabled by default
Using config: /usr/local/zookeeper/bin/ ../conf/zoo.cfg
Client port found: 2181. Client address: localhost. Client SSL: false.
Mode: leader
```

```
hadoop@mashuai03:/usr/local/zookeeper/bin$ ./zkServer.sh status
ZooKeeper JMX enabled by default
Using config: /usr/local/zookeeper/bin/ ../conf/zoo.cfg
Client port found: 2181. Client address: localhost. Client SSL: false.
Mode: follower
```

会看到，有一个节点的Mode是leader，另外两个是follower。具体哪个会是leader是zookeeper自己选举出来的。

以下环境部署，基于前面课程修改配置，将原来的hadoop环境修改为HA

## 10. 【A、B、C】修改hadoop的配置文件

core-site.xml

```
1 <configuration>
2 <property>
3     <name>fs.defaultFS</name>
4     <value>hdfs://mycluster</value>
5 </property>
6 <property>
7     <name>hadoop.tmp.dir</name>
8     <value>file:/usr/local/hadoop/tmp</value>
9 </property>
10 <!-- 指定 zkfc 要连接的 zkServer 地址 -->
11 <property>
```

```
12 <name>ha.zookeeper.quorum</name>
13 <value>mashuai01:2181,mashuai02:2181,mashuai03:2181</value>
14 </property>
15 </configuration>
16
```

## hdfs-site.xml

```
1
2 <configuration>
3     <!--<property>
4         <name>dfs.namenode.secondary.http-address</name>
5         <value>mashuai02:9868</value>
6     </property>-->
7 <property>
8     <name>dfs.namenode.name.dir</name>
9     <value>file:/usr/local/hadoop/dfs/name</value>
10 </property>
11
12 <property>
13     <name>dfs.datanode.data.dir</name>
14     <value>file:/usr/local/hadoop/dfs/data</value>
15 </property>
16
17 <property>
18     <name>dfs.replication</name>
19     <value>3</value>
20 </property>
21
22 <!-- JournalNode 数据存储目录 -->
23 <property>
24     <name>dfs.journalnode.edits.dir</name>
25     <value>/usr/local/hadoop/tmp/jn</value>
26 </property>
27 <!-- 完全分布式集群名称 -->
28 <property>
29     <name>dfs.nameservices</name>
30     <value>mycluster</value>
```

```
31 </property>
32 <!-- 集群中 NameNode 节点都有哪些 -->
33 <property>
34 <name>dfs.ha.namenodes.mycluster</name>
35 <value>nn1,nn2,nn3</value>
36 </property>
37 <!-- NameNode 的 RPC 通信地址 -->
38 <property>
39 <name>dfs.namenode.rpc-address.mycluster.nn1</name>
40 <value>mashuai01:8020</value>
41 </property>
42 <property>
43 <name>dfs.namenode.rpc-address.mycluster.nn2</name>
44 <value>mashuai02:8020</value>
45 </property>
46 <property>
47 <name>dfs.namenode.rpc-address.mycluster.nn3</name>
48 <value>mashuai03:8020</value>
49 </property>
50 <!-- NameNode 的 http 通信地址 -->
51 <property>
52 <name>dfs.namenode.http-address.mycluster.nn1</name>
53 <value>mashuai01:9870</value>
54 </property>
55 <property>
56 <name>dfs.namenode.http-address.mycluster.nn2</name>
57 <value>mashuai02:9870</value>
58 </property>
59 <property>
60 <name>dfs.namenode.http-address.mycluster.nn3</name>
61 <value>mashuai03:9870</value>
62 </property>
63 <!-- 指定 NameNode 元数据在 JournalNode 上的存放位置 -->
64 <property>
65 <name>dfs.namenode.shared.edits.dir</name>
66 <value>qjournal://mashuai01:8485;mashuai02:8485;mashuai03:8485/mycluster</value>
67 </property>
68 <!-- 访问代理类: client 用于确定哪个 NameNode 为 Active -->
69 <property>
70 <name>dfs.client.failover.proxy.provider.mycluster</name>
```

```

71 <value>org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider</value>
72 </property>
73 <!-- 配置隔离机制，即同一时刻只能有一台服务器对外响应 -->
74 <property>
75 <name>dfs.ha.fencing.methods</name>
76 <value>sshfence</value>
77 </property>
78 <!-- 使用隔离机制时需要 ssh 秘钥登录 下面的路径改成自己的-->
79 <property>
80 <name>dfs.ha.fencing.ssh.private-key-files</name>
81 <value>/home/hadoop/.ssh/id_rsa</value>
82 </property>
83 <!-- 启用 nn 故障自动转移 -->
84 <property>
85 <name>dfs.ha.automatic-failover.enabled</name>
86 <value>true</value>
87 </property>
88 </configuration>
89

```

## yarn-site.xml

```

1 <configuration>
2 <property>
3   <name>yarn.nodemanager.aux-services</name>
4   <value>mapreduce_shuffle</value>
5 </property>
6 <!--
7 <property>
8   <name>yarn.nodemanager.auxservices.mapreduce.shuffle.class</name>
9   <value>org.apache.hadoop.mapred.ShuffleHandler</value>
10 </property>
11
12 <property>
13   <name>yarn.resourcemanager.address</name>
14   <value>mashuai01:8032</value>
15 </property>

```

```
16 -->
17 <!-- 启用 resourcemanager ha -->
18 <property>
19 <name>yarn.resourcemanager.ha.enabled</name>
20 <value>true</value>
21 </property>
22 <!-- 声明两台 resourcemanager 的地址 -->
23 <property>
24 <name>yarn.resourcemanager.cluster-id</name>
25 <value>cluster-yarn1</value>
26 </property>
27 <!--指定 resourcemanager 的逻辑列表-->
28 <property>
29 <name>yarn.resourcemanager.ha.rm-ids</name>
30 <value>rm1,rm2,rm3</value>
31 </property>
32 <!-- ===== rm1 的配置 ===== -->
33 <!-- 指定 rm1 的主机名 -->
34 <property>
35 <name>yarn.resourcemanager.hostname.rm1</name>
36 <value>mashuai01</value>
37 </property>
38 <!-- 指定 rm1 的 web 端地址 -->
39 <property>
40 <name>yarn.resourcemanager.webapp.address.rm1</name>
41 <value>mashuai01:8088</value>
42 </property>
43 <!-- ===== rm2 的配置 ===== -->
44 <!-- 指定 rm2 的主机名 -->
45 <property>
46 <name>yarn.resourcemanager.hostname.rm2</name>
47 <value>mashuai02</value>
48 </property>
49 <property>
50 <name>yarn.resourcemanager.webapp.address.rm2</name>
51 <value>mashuai02:8088</value>
52 </property>
53 <!-- ===== rm3 的配置 ===== -->
54 <!-- 指定 rm1 的主机名 -->
55 <property>
```

```
56 <name>yarn.resourcemanager.hostname.rm3</name>
57 <value>mashuai03</value>
58 </property>
59 <!-- 指定 rm1 的 web 端地址 -->
60 <property>
61 <name>yarn.resourcemanager.webapp.address.rm3</name>
62 <value>mashuai03:8088</value>
63 </property>
64 <!-- 指定 rm1 的内部通信地址 -->
65 <!-- 指定 zookeeper 集群的地址 -->
66 <property>
67 <name>yarn.resourcemanager.zk-address</name>
68 <value>mashuai01:2181,mashuai02:2181,mashuai03:2181</value>
69 </property>
70 <!-- 启用自动恢复 -->
71 <property>
72 <name>yarn.resourcemanager.recovery.enabled</name>
73 <value>true</value>
74 </property>
75 <!-- 指定 resourcemanager 的状态信息存储在 zookeeper 集群 -->
76 <property>
77 <name>yarn.resourcemanager.store.class</name>
78 <value>org.apache.hadoop.yarn.server.resourcemanager.recovery.ZKRMStateStore</value>
79 </property>
80 <!-- 环境变量的继承 -->
81 <property>
82     <name>yarn.nodemanager.env-whitelist</name>
83
84     <value>JAVA_HOME,HADOOP_COMMON_HOME,HADOOP_HDFS_HOME,HADOOP_CONF_DIR,CLASSPATH_PREPEND_
DISTCACHE,HADOOP_YARN_HOME,HADOOP_HOME,PATH,LANG,TZ,HADOOP_MAPRED_HOME</value>
85 </property>
86 <property>
87     <name>yarn.nodemanager.vmem-check-enabled</name>
88     <value>>false</value>
89 </property>
90 <!-- Site specific YARN configuration properties -->
91 </configuration>
92
```

## 11. 【A】 拷贝hadoop的配置文件到B,C

```
1  scp ../etc/hadoop/*  hadoop@mashuai02:/usr/local/hadoop/etc/hadoop
2  scp ../etc/hadoop/*  hadoop@mashuai03:/usr/local/hadoop/etc/hadoop
```

## 12. 【A,B,C】 在各个JournalNode节点上，输入一下命令启动journalnode服务

```
1  hdfs --daemon start journalnode
```

这时jps可以看到journalnode进程

## 13. 【A】 在 nn1 上，对其进行格式化，并启动

```
1  cd /usr/local/hadoop/
2  rm -r dfs/ logs/ tmp/
3  hdfs namenode -format
4  hdfs --daemon start namenode
```

## 14. 【B、 C】 在 nn2和 nn3 ， 同步nn1 的元数据信息

```
1  cd /usr/local/hadoop/
2  rm -r dfs/ logs/ tmp/
3  hdfs namenode -bootstrapStandby
```

## 15. 【B、 C】 启动 nn2 和 nn3

```
1  hdfs --daemon start namenode
```

## 16 【A】 查看web界面 9870

# Overview 'mashuai01:8020' (standby)

|              |                                                  |
|--------------|--------------------------------------------------|
| Namespace:   | mycluster                                        |
| Namenode ID: | nn1                                              |
| Started:     | Wed Mar 20 21:59:23 +0800 2024                   |
| Version:     | 3.1.3, rba631c436b806728f8ec2f54ab1e289526c90579 |

17. 【A,B,C】 在所有节点， 启动datanode

```
1 hdfs --daemon start datanode
```

18. 【A】 在A节点上格式化zkfc:

```
1 hdfs zkfc -formatZK
```

19. 【A、 B、 C】 在各个NameNode节点上启动DFSZK Failover Controller，  
先在哪台机器启动， 哪个机器的NameNode就是Active NameNode

```
1 hdfs --daemon start zkfc
2 手动切换故障节点，可不执行
3 hdfs haadmin -failover nn1 nn2
```

jps查看进程，发现zkfc进程正常运行。hdfs zkfc -formatZK，没有格式化整个Zookeeper，只是在Zookeeper中创建了路径/hadoop-ha/hacluster。

20. 【A,B,C】 修改start-dfs.sh和stop-dfs.sh文件，添加下列参数

```
HDFS_NAMENODE_USER=hadoop
HDFS_DATANODE_USER=hadoop
```

HDFS\_JOURNALNODE\_USER=hadoop  
HDFS\_ZKFC\_USER=hadoop  
HADOOP\_SECURE\_DN\_USER=hadoop  
HDFS\_SECONDARYNAMENODE\_USER=hadoop  
添加后使用source一下，生效

## 21. 【A,B,C】在start-yarn.sh stop-yarn.sh中添加

YARN\_RESOURCEMANAGER\_USER=hadoop  
YARN\_NODEMANAGER\_USER=hadoop  
添加后使用source一下，生效

## 22. 【A】启动yarn

```
1 `start-yarn.sh
```

- 查看服务状态

```
1 yarn rmadmin -getServiceState rm1
```

- 可以去 zkCli.sh 客户端查看 ResourceManager 选举锁节点内容

```
[root@server1 sbin]# yarn rmadmin -getServiceState rm1
2023-11-30 11:36:42,592 WARN util.NativeCodeLoader: Unable to load native-hadoop library for your platform... using builtin-java classes where applicable
standby
[root@server1 sbin]# yarn rmadmin -getServiceState rm2
2023-11-30 11:36:49,396 WARN util.NativeCodeLoader: Unable to load native-hadoop library for your platform... using builtin-java classes where applicable
active
[root@server1 sbin]# yarn rmadmin -getServiceState rm3
2023-11-30 11:36:54,733 WARN util.NativeCodeLoader: Unable to load native-hadoop library for your platform... using builtin-java classes where applicable
standby
[root@server1 sbin]#
```

---

## 【补充】关机后启动方法

### 1. 【A、 B、 C】启动zookeeper， 每节点启动

```
1 zkServer.sh start
```

### 2. 【A】启动hdfs， 主节点启动

```
1 start-dfs.sh
```

3. ~~【A、B、C】启动zkfc，每节点启动~~

```
1 hdfs --daemon start zkfc
```

4. **【A】启动yarn，主节点启动**

```
1 start-yarn.sh
```

验证进程启动是否成功

```
hadoop@mashuai01:~$ jps
4080 ResourceManager
1970 NameNode
2082 DataNode
4195 NodeManager
3510 DFSZKFailoverController
5624 Jps
1772 QuorumPeerMain
2303 JournalNode
```

```
hadoop@mashuai02:~$ jps
25136 DataNode
26035 DFSZKFailoverController
27316 Jps
26437 ResourceManager
25254 JournalNode
26520 NodeManager
19146 QuorumPeerMain
25039 NameNode
```

```
hadoop@mashuai03:~$ jps
19873 DFSZKFailoverController
21618 Jps
13732 QuorumPeerMain
18869 NameNode
18966 DataNode
20152 ResourceManager
20235 NodeManager
19083 JournalNode
```

验证hdfs的namenode的active是否可以自动迁移，使用

```
hdfs --daemon stop namenode
```

或者

```
ps -ef | grep namenode
```

```
kill -9 pid
```

停止namenode，但是发现另外两台机器并没有新的active出现，仍然是两个standby，经过查找资料，通过以下方式 修改hdfs-site.xml可以解决。

## hadoop相关问题

### 序：namenode高可用问题

namenode的高可用是由QJM和zkfc加zk集群来实现的，当宕机再启动的时候，会切换很快，但是如果直接宕机或者是hang机，当ssh无法登录上去的时候，就会导致切换不成功，一直为standby状态。。。需要登录上去，进行探测namenode进程是否存在，如果存在则杀死，这就是sshfence的实现，但是在宕机的时候，也可以切换，必须修改为如下配置：

```
1 <property>
2     <name>dfs.ha.fencing.methods</name>
3     <value>
4         sshfence
5         shell(/bin/true)
6     </value>
7 </property>
```