
单项选择题

1. 下面哪个程序负责 HDFS 数据存储。

- a)NameNode
- b)Jobtracker
- c)Datanode
- d)secondaryNameNode
- e)tasktracker

2. HDFS 中的 block 默认保存几份?

- a)3 份
- b)2 份
- c)1 份
- d)不确定

3. 下列哪个程序通常与 NameNode 在一个节点启动?

- a)SecondaryNameNode
- b)DataNode
- c)TaskTracker
- d)Jobtracker

4. Hadoop 作者

- a)Martin Fowler
- b)Kent Beck
- c)Doug cutting

5. HDFS 默认 Block Size

- a)32MB
- b)64MB

..

c)128MB

6. 下列哪项通常是集群的最主要瓶颈

a)CPU

b)网络

c)磁盘

d)内存

7. 关于 SecondaryNameNode 哪项是正确的?

a)它是 NameNode 的热备

b)它对内存没有要求

c)它的目的是帮助 NameNode 合并编辑日志，减少 NameNode 启动时间

d)SecondaryNameNode 应与 NameNode 部署到一个节点

多选题

8. 下列哪项可以作为集群的管理工具

a)Puppet

b)Pdsh

c)Cloudera Manager

d)d)Zookeeper

9. 配置机架感知的下面哪项正确

a)如果一个机架出问题，不会影响数据读写

..

b)写入数据的时候会写到不同机架的 **DataNode** 中

c)**MapReduce** 会根据机架获取离自己比较近的网络数据

10. **Client** 端上传文件的时候下列哪项正确

a)数据经过 **NameNode** 传递给 **DataNode**

b)**Client** 端将文件切分为 **Block** , 依次上传

c)**Client** 只上传数据到一台 **DataNode** , 然后由 **NameNode** 负责

Block 复制工作

11. 下列哪个是 **Hadoop** 运行的模式

a)单机版

b)伪分布式

c)分布式

12. **Cloudera** 提供哪几种安装 **CDH** 的方法

a)**Cloudera manager**

b)**Tar ball**

c)**Yum** d)**Rpm**

判断题

13. **Ganglia** 不仅可以进行监控 , 也可以进行告警。()

14. **Block Size** 是不可以修改的。()

-
15. Nagios 不可以监控 Hadoop 集群，因为它不提供 Hadoop 支持。()
16. 如果 NameNode 意外终止，SecondaryNameNode 会接替它使集群继续工作。()
17. Cloudera CDH 是需要付费使用的。()
18. Hadoop 是 Java 开发的，所以 MapReduce 只支持 Java 语言编写。()
19. Hadoop 支持数据的随机读写。()
20. NameNode 负责管理 metadata，client 端每次读写请求，它都会从磁盘中读取或则会写入 metadata 信息并反馈 client 端。()
21. NameNode 本地磁盘保存了 Block 的位置信息。()
22. DataNode 通过长连接与 NameNode 保持通信。()
23. Hadoop 自身具有严格的权限管理和安全措施保障集群正常运行。()
24. Slave 节点要存储数据，所以它的磁盘越大越好。()
25. `hadoop dfsadmin -report` 命令用于检测 HDFS 损坏块。()
26. Hadoop 默认调度器策略为 FIFO()

-
27. 集群内每个节点都应该配 RAID，这样避免单磁盘损坏，影响整个节点运行。()
28. 因为 HDFS 有多个副本，所以 NameNode 是不存在单点问题的。()
29. 每个 map 槽就是一个线程。()
30. Mapreduce 的 input split 就是一个 block。()
31. NameNode 的 Web UI 端口是 50030，它通过 jetty 启动的 Web 服务。()
32. Hadoop 环境变量中的 HADOOP_HEAPSIZE 用于设置所有 Hadoop 守护线程的内存。它默认是 200 GB。()
33. DataNode 首次加入 cluster 的时候，如果 log 中报告不兼容文件版本，那需要 NameNode 执行“Hadoop namenode -format”操作格式化磁盘。()

别走开，答案在后面哦!

答案

单选题

1. 下面哪个程序负责 HDFS 数据存储。答案C datanode

- a)NameNode
- b)Jobtracker
- c)Datanode
- d)secondaryNameNode
- e)tasktracker

2. HDFS 中的 block 默认保存几份? 答案A默认3分

- a)3 份
- b)2 份
- c)1 份
- d)不确定

3. 下列哪个程序通常与 NameNode 在一个节点启动?答案D

- a)SecondaryNameNode
- b)DataNode
- c)TaskTracker
- d)Jobtracker

此题分析：

hadoop的集群是基于master/slave模式，namenode和jobtracker属于master，datanode和tasktracker属于slave，master只有一个，而slave有多个SecondaryNameNode内存需求和NameNode在一个数量级上，所以通常secondary NameNode(运行在单独的物理机器上)和NameNode运

行在不同的机器上。

JobTracker和TaskTracker

JobTracker 对应于 NameNode

TaskTracker 对应于 DataNode

DataNode 和NameNode 是针对数据存放来而言的

JobTracker和TaskTracker是对于MapReduce执行而言的

mapreduce中几个主要概念，mapreduce整体上可以分为这么几条执行线索：obclient，JobTracker与TaskTracker。

1、JobClient会在用户端通过JobClient类将应用已经配置参数打包成jar文件存储到hdfs，并把路径提交到Jobtracker,然后由JobTracker创建每一个Task(即MapTask和ReduceTask)并将它们分发到各个TaskTracker服务中去执行。

2、JobTracker是一个master服务，软件启动之后JobTracker接收Job，负责调度Job的每一个子任务task运行于TaskTracker上，并监控它们，如果发现失败的task就重新运行它。一般情况应该把JobTracker部署在单独的机器上。

3、TaskTracker是运行在多个节点上的slaver服务。TaskTracker主动与JobTracker通信，接收作业，并负责直接执行每一个任务。TaskTracker都需

要运行在HDFS的DataNode上。

4. Hadoop 作者 答案C Doug cutting

- a)Martin Fowler
- b)Kent Beck
- c)Doug cutting

5. HDFS 默认 Block Size 答案 : B

- a)32MB
- b)64MB
- c)128MB

(因为版本更换较快，这里答案只供参考)

6. 下列哪项通常是集群的最主要瓶颈：答案：C磁盘

- a)CPU
- b)网络
- c)磁盘IO
- d)内存

该题解析：

首先集群的目的是为了节省成本，用廉价的pc机，取代小型机及大型机。小型机和大型机有什么特点？

1.cpu处理能力强

2.内存够大

所以集群的瓶颈不可能是a和d

3.网络是一种稀缺资源，但是并不是瓶颈。

4.由于大数据面临海量数据，读写数据都需要io，然后还要冗余数据，
hadoop一般备3份数据，所以IO就会打折扣。

7. 关于 SecondaryNameNode 哪项是正确的?答案C

a)它是 NameNode 的热备

b)它对内存没有要求

c)它的目的是帮助 NameNode 合并编辑日志，减少 NameNode 启动时间

d)SecondaryNameNode 应与 NameNode 部署到一个节点。

多选题

8. 下列哪项可以作为集群的管理?答案：ABD

a)Puppet

b)Pdsh

c)Cloudera Manager

d)Zookeeper

9. 配置机架感知的下面哪项正确：答案ABC

a)如果一个机架出问题，不会影响数据读写

b)写入数据的时候会写到不同机架的 **DataNode** 中

c)**MapReduce** 会根据机架获取离自己比较近的网络数据

10. **Client** 端上传文件的时候下列哪项正确?答案B

a)数据经过 **NameNode** 传递给 **DataNode**

b)**Client** 端将文件切分为 **Block** , 依次上传

c)**Client** 只上传数据到一台 **DataNode** , 然后由 **NameNode** 负责

Block 复制工作

该题分析 :

Client向**NameNode**发起文件写入的请求。

NameNode根据文件大小和文件块配置情况 , 返回给**Client**它所管理部分 **DataNode**的信息。

Client将文件划分为多个**Block** , 根据**DataNode**的地址信息 , 按顺序写入到每一个**DataNode**块中。

11. 下列哪个是 **Hadoop** 运行的模式 : 答案ABC

a)单机版

b)伪分布式

c)分布式

12. Cloudera 提供哪几种安装 CDH 的方法?答案 : ABCD

- a)Cloudera manager
- b)Tarball
- c)Yum
- d)Rpm

判断题

13. Ganglia 不仅可以进行监控，也可以进行告警。(正确)

分析：此题的目的是考Ganglia的了解。严格意义上来讲是正确。ganglia作为一款最常用的Linux环境中的监控软件，它擅长的的是从节点中按照用户的需求以较低的代价采集数据。但是ganglia在预警以及发生事件后通知用户上并不擅长。最新的ganglia已经有了部分这方面的功能。但是更擅长做警告的还有Nagios。Nagios，就是一款精于预警、通知的软件。通过将Ganglia和Nagios组合起来，把Ganglia采集的数据作为Nagios的数据源，然后利用Nagios来发送预警通知，可以完美的实现一整套监控管理的系统。

14. Block Size 是不可以修改的。(错误)

分析：它是可以被修改的Hadoop的基础配置文件是hadoop-default.xml，默认建立一个Job的时候会建立Job的Config，Config首先读入hadoop-default.xml的配置，然后再读入hadoop-site.xml的配置(这个文件初始的时候配置为空)，hadoop-site.xml中主要配置需要覆盖的hadoop-

default.xml的系统级配置。

15. Nagios 不可以监控 Hadoop 集群，因为它不提供 Hadoop 支持。

(错误)

分析：Nagios是集群监控工具，而且是云计算三大利器之一

16. 如果 NameNode 意外终止，SecondaryNameNode 会接替它使集群继续工作。(错误)

分析：SecondaryNameNode是帮助恢复，而不是替代，如何恢复，可以查看

17. Cloudera CDH 是需要付费使用的。(错误)

分析：第一套付费产品是Cloudera Enterprise，Cloudera Enterprise在美国加州举行的 Hadoop 大会 (Hadoop Summit) 上公开，以若干私有管理、监控、运作工具加强 Hadoop 的功能。收费采取合约订购方式，价格随用的 Hadoop 叢集大小变动。

18. Hadoop 是 Java 开发的，所以 MapReduce 只支持 Java 语言编写。

(错误)

分析：rhadoop是用R语言开发的，MapReduce是一个框架，可以理解是

一种思想，可以使用其他语言开发。

19. Hadoop 支持数据的随机读写。(错)

分析：lucene是支持随机读写的，而hdfs只支持随机读。但是HBase可以用来补救。HBase提供随机读写，来解决Hadoop不能处理的问题。HBase自底层设计开始即聚焦于各种可伸缩性问题：表可以很“高”，有数十亿个数据行；也可以很“宽”，有数百万个列；水平分区并在上千个普通商用机节点上自动复制。表的模式是物理存储的直接反映，使系统有可能提高高效的数据结构的序列化、存储和检索。

20. NameNode 负责管理 metadata，client 端每次读写请求，它都会从磁盘中读取或则会写入 metadata 信息并反馈 client 端。(错误)

此题分析：

NameNode 不需要从磁盘读取 metadata，所有数据都在内存中，硬盘上的只是序列化的结果，只有每次 namenode 启动的时候才会读取。

1)文件写入

Client向NameNode发起文件写入的请求。

NameNode根据文件大小和文件块配置情况，返回给Client它所管理部分DataNode的信息。

Client将文件划分为多个**Block**，根据**DataNode**的地址信息，按顺序写入到每一个**DataNode**块中。

2)文件读取**Client**向**NameNode**发起文件读取的请求。

21. NameNode 本地磁盘保存了 **Block** 的位置信息。(个人认为 正确 , 欢迎提出其它意见)

分析：**DataNode**是文件存储的基本单元，它将**Block**存储在本地文件系统中，保存了**Block**的**Meta-data**，同时周期性地将所有存在的**Block**信息发送给**NameNode**。**NameNode**返回文件存储的**DataNode**的信息。**Client**读取文件信息。

22. DataNode 通过长连接与 **NameNode** 保持通信。()

这个有分歧：具体正在找这方面的有利资料。下面提供资料可参考。

首先明确一下概念：

(1).长连接**Client**方与**Server**方先建立通讯连接，连接建立后不断开，然后再进行报文发送和接收。这种方式下由于通讯连接一直存在，此种方式常用于点对点通讯。

(2).短连接Client方与Server每进行一次报文收发交易时才进行通讯连接，交易完毕后立即断开连接。此种方式常用于一点对多点通讯，比如多个Client连接一个Server.

23. Hadoop 自身具有严格的权限管理和安全措施保障集群正常运行。(错误)

hadoop只能阻止好人犯错，但是不能阻止坏人干坏事

24. Slave 节点要存储数据，所以它的磁盘越大越好。(错误)

分析：一旦Slave节点宕机，数据恢复是一个难题

25. hadoop dfsadmin -report 命令用于检测 HDFS 损坏块。(错误)

26. Hadoop 默认调度器策略为 FIFO(正确)

27. 集群内每个节点都应该配 RAID，这样避免单磁盘损坏，影响整个节点运行。(错误)

分析：首先明白什么是RAID，可以参考百科磁盘阵列。这句话错误的地方在于太绝对，具体情况具体分析。题目不是重点，知识才是最重要的。因为hadoop本身就具有冗余能力，所以如果不是很严格不需要都配备RAID。具体参考第二题。

28. 因为 HDFS 有多个副本，所以 NameNode 是不存在单点问题的。(错误)

29. 每个 map 槽就是一个线程。(错误)

分析：首先我们知道什么是map 槽, map 槽->map slot
map slot 只是一个逻辑值
(org.apache.hadoop.mapred.TaskTracker.TaskLauncher.numFreeSlots)，而不是对应着一个线程或者进程

30. Mapreduce 的 input split 就是一个 block。(错误)

31. NameNode 的 Web UI 端口是 50030，它通过 jetty 启动的 Web 服务。(错误)

32. Hadoop 环境变量中的 HADOOP_HEAPSIZE 用于设置所有 Hadoop 守护线程的内存。它默认是 200 GB。(错误)

hadoop为各个守护进程
(namenode,secondarynamenode,jobtracker,datanode,tasktracker)统一分配的内存存在hadoop-env.sh中设置，参数为
HADOOP_HEAPSIZE，默认为1000M。

33. DataNode 首次加入 cluster 的时候，如果 log 中报告不兼容文件版

本，那需要 **NameNode** 执行“**Hadoop namenode -format**”操作格式化磁盘。(错误)

分析：

首先明白介绍，什么**ClusterID**

ClusterID

添加了一个新的标识符**ClusterID**用于标识集群中所有的节点。当格式化一个**Namenode**，需要提供这个标识符或者自动生成。这个**ID**可以被用来格式化加入集群的其他**Namenode**。

二次整理

有的同学问题的重点不是上面分析内容：内容如下：

这个报错是说明 **DataNode** 所装的**Hadoop**版本和其它节点不一致，应该检查**DataNode**的**Hadoop**版本