



# MongoDB在东航的应用实践

东航信息部西北分中心

彭长华

信 息 部  
IT SOLUTION

# About Me

```
{  
  "_id" : ObjectId("5b0e640e7007c9db7eb6c834"),  
  "姓名" : "彭长华",  
  "公司" : "东方航空",  
  "部门" : "信息部西北分中心研发分部",  
  "职位" : "技术总监",  
  "软件研发经验" : "11年",  
  "mongoDB使用经验" : "4年"  
}
```

# 目录



- 1 东航应用场景
- 2 部署架构选择
- 3 设计模式
- 4 性能监控
- 5 性能优化



# 1

## 东航应用场景



## 1.1 东航的应用场景

东方航空于2014年初就开始使用MongoDB，目前有很多生产系统在使用。



1

### 航班搜索引擎

采用复制集架构，支持日均**3000W+**的航班查询，以及**2亿条**的库存数据及运价缓存，**99%以上**查询效率低于**200ms**。



2

### 旅客实时服务平台

采用复制集架构，支持日均**上千万**的数据处理量，和**3亿次**的服务查询量，涉及到高并发读写。



3

### Customer系统

基于旅客大数据分析从不同角度计算各个旅客的价值，采用分片架构支持**20亿**条数据存储量。

## 1.2 东航的应用场景



### 1 航班搜索引擎

### 2 旅客实时服务平台

### 3 Customer系统

男 35 y.o (1983.02.20)  
中国 海 [redacted] 普卡客户

经济舱 cabin 中间 seat

7 一年飞行次数  
¥0 飞行平均花费  
200 mcv

0 遭遇不正常航班的次数  
0 SRI

2018-05-30 星期三  
09:13:49

SINGLE VIEW

基础信息

CustID: 2050000000000000202446644  
身份证: [redacted]  
护照号: 暂无  
常客等级: 普卡客户  
常客号码: [redacted]

更多

行程信息

我的飞行计划(0)

已经完成的行程(20)

| 航班号    | 出发机场 | 到达机场 | 出发日期       | 出发时间  |
|--------|------|------|------------|-------|
| MU2166 | SHA  | XIY  | 2018.04.29 | 17:55 |
| MU2151 | XIY  | SHA  | 2018.04.29 | 09:00 |
| MU2120 | PEK  | XIY  | 2018.04.27 | 21:05 |
| MU2105 | XIY  | PEK  | 2018.04.25 | 11:20 |

REGENCY

7天 30天 90天 一年 一年以上

FREQUENCY

0-1 2-5 5-10 10-50 50次以上

MONETARY

0-1千 1-3千 3-10千 1-5万 5万以上

高舱比例

NOSHOW 比例

出行时间 统计

附加服务 统计

偏好出发: 西安 市

偏好舱位: 经济 舱

偏好座位: ABC 位: 中间

SRI: 0



# 2

## 部署架构选择



## 2.1.部署架构一（复制集）

### 项目类型


航班搜索引擎、旅客实时服务平台

### 数据量

支持千万级的数据处理量，和上亿次的服务查询量，99%以上查询效率低于200ms

### 硬件配置

3台 64 核 512G SSD硬盘



服务器的增加能否提高集群的读写处理能力？

## 2.2.部署架构二（分片）

### 项目类型


Customer系统

### 数据量

用户数8000W+，数据总量有20亿+，同时数据是一个不断增长的过程。

### 硬件配置

6台 8核 16G 500G，二个分片。





# 3

## 设计模式



## 3.1.设计原则

### 关注点

- 应用需要什么数据。
- 应用如何读取数据，采用哪些条件进行查询，以及查询频率。
- 应用如何写数据，写入频率。

### 遵循原则

- 为性能优化，而不是空间。
- 为最重要场景优化，不求面面俱到。

### 限制条件

- 单个文档最大不能超过 16M。
- ACID 事务：3.X 版本原子更新仅限于单文档
- 数组不宜无限制频繁增长。

## 3.2. 1对1

**场景** 旅客某天出行的订座、出票、值机、安检和登机等信息

**优点** 执行一次查询就可以获得旅客的相关信息

**缺点** 无法像操作独立文档那样来操作订座等信息。必须首先操作（比如查询）旅客文档后，才有可能继续操作订座或值机信息。

```

    "idtype" : "PSPT",
    "number" : "123456789",
    "type" : "ADT",
    "surName" : "YAE...",
    "givenName" : "TANAKA...",
  },
  "seg" : {
    "carrier" : "MU",
    "flightNumber" : "537",
    "departureAirPort" : "SHA",
    "departureDate" : "2016-08-03T00:00:00",
    "departureTime" : "10:00:00",
    "arrivalAirPort" : "PEK",
    "arrivalTime" : "2016-08-03T13:00:00",
    "arrivalDate" : "2016-08-03T00:00:00",
  },
  "book" : {
    "bookingOffice" : "",
    "iataCode" : "",
    "gdsCode" : "",
    "gdsRecord" : "",
    "record" : "MC5691",
    "group" : "N",
    "groupName" : ""
  },
  "checkIn" : {
    "status" : "ACC",
    "checkInDate" : "2016-08-03T07:00:00",
    "baggage" : "N",
    "location" : "8A",
  }

```

旅客信息

订座信息

值机信息

## 3.3 1对N

**场景** 查询航班下多个舱位的价格

**优点** 执行一次查询就可以获得航班下所有舱位价格

**缺点** 无法像操作独立文档那样来操作舱位信息,必须首先操作(比如查询)航班文档后,才有可能继续操作舱位信息

内嵌所有舱位价格

```
"flightInfo" : {
  "carrier" : "MU",
  "flightNo" : "9201",
  "oriEng" : "SHA",
  "desEng" : "XIY",
  "flightDt" : ISODate("2018-07-23T00:00:00Z"),
},
"fareInfo" : [
  {
    "clas_tp" : "C",
    "price" : "2220",
  },
  {
    "clas_tp" : "J",
    "price" : "4310",
  },
  {
    "clas_tp" : "F",
    "price" : "5390",
  },
  {
    "clas_tp" : "Y",
    "fd_price" : "1390",
    "price" : "1390",
    "promocode" : ""
  },
  {
    "clas_tp" : "Z",
    "price" : "450",
  }
]
```

## 3.4. 1对NN

### 场景

查询飞机上所有零部件信息

```
{
  "actype" : "A320",
  "tailNO" : "B2306",
  "productDate" : ISODate("2017-03-02T00:00:00.000+08"),
  "manufacturer" : "Airbus Corp",
  "parts" : [
    ObjectId("5ad170ec71f8ebc28c657dc4"),
    ObjectId("5ad170ff71f8ebc28c657dc5"),
    ObjectId("5ad170ff71f8ebc28c657dc6")
  ]
}
```

飞机信息

```
"_id" : ObjectId("5ad170ec71f8ebc28c657dc4"),
"partno" : "123-aff-456",
"name" : "#4 cabin",
"qty" : 1,
"cost" : 0.94,
"price" : 113.99
```

```
"_id" : ObjectId("5ad170ff71f8ebc28c657dc5"),
"partno" : "123-aff-457",
"name" : "#4 cockpit",
"qty" : 1,
"cost" : 1,
"price" : 113.99
```

零部件信息

```
var p = db.getCollection('aircraft').findOne({"tailNO":"B2306"});
r= db.parts.find({_id:{$in: p.parts}});
print(r)
```

## 3.5. 1对NNN

### 场景

统计每台服务器产生的大量日志。

```
{
  "_id" : ObjectId("5ad1790c71f8ebc28c657dc7"),
  "name" : "xb.ceair.com",
  "ipaddr" : "127.18.80.66"
}
{
  "_id" : ObjectId("5ad6d99c68a40ed768c610ac"),
  "name" : "xa.ceair.com",
  "ipaddr" : "127.18.80.67"
}
```

服务器信息

```
"_id" : ObjectId("5ad1799c71f8ebc28c657dc8"),
"hostId" : ObjectId("5ad1790c71f8ebc28c657dc7"),
"createTime" : ISODate("2018-03-28T17:42:41.382"),
"level" : "ERROR",
"message" : "not enough disc space"
```

```
"_id" : ObjectId("5ad17a4a71f8ebc28c657dc9"),
"hostId" : ObjectId("5ad1790c71f8ebc28c657dc7"),
"createTime" : ISODate("2018-03-28T17:42:41.382"),
"level" : "ERROR",
"message" : "out of memeory"
```

日志信息

```
var h = db.getCollection('hosts').findOne({ "name" : "xb.ceair.com"})
var logs = db.log.find({"hostId" : h._id})
print(logs)
```

## 3.6.设计模式比较

### 总结

- 集合设计由业务驱动，非数据驱动
- 优先考虑内嵌，忘掉关系型数据库范式设计
- 适当的冗余设计

| 关注点     | 引用设计         | 内嵌设计                 |
|---------|--------------|----------------------|
| 更新效率    | 最高           | 最低                   |
| 查询效率    | 最低           | 最高                   |
| 适合子文档大小 | 子文档大         | 子文档小                 |
| 子文档增幅   | 大            | 小                    |
| 事务性     | 无跨表事务(3.X版本) | 支持                   |
| 适用场合    | 一对非常多，多对多    | 一对一，一对很少且不需要单独访问内嵌内容 |



# 4

# 性能监控



## 4.1. mongostat

`./mongostat --host 127.0.0.1 --port 27117`

| insert | query | update | delete | getmore | command | dirty | used | flushes | vsize | res   | grw  | arw | net_in | net_out | conn  | set | repl | time                    |
|--------|-------|--------|--------|---------|---------|-------|------|---------|-------|-------|------|-----|--------|---------|-------|-----|------|-------------------------|
| *0     | *0    | *0     | *0     | 0       | 2       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 142M | 0   | 0      | 158b    | 59.8k | 16  | rs1  | PRI May 11 10:01:45.672 |
| *0     | *0    | *0     | *0     | 0       | 4       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 142M | 0   | 0      | 686b    | 60.8k | 16  | rs1  | PRI May 11 10:01:46.671 |
| *0     | *0    | *0     | *0     | 1       | 3       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 2.42k   | 61.5k | 16  | rs1  | PRI May 11 10:01:47.674 |
| *0     | *0    | *0     | *0     | 0       | 4       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 687b    | 60.9k | 16  | rs1  | PRI May 11 10:01:48.671 |
| *0     | *0    | *0     | *0     | 0       | 2       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 158b    | 59.7k | 16  | rs1  | PRI May 11 10:01:49.671 |
| *0     | *0    | *0     | *0     | 0       | 3       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 685b    | 60.7k | 16  | rs1  | PRI May 11 10:01:50.672 |
| *0     | *0    | *0     | *0     | 0       | 2       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 158b    | 59.8k | 16  | rs1  | PRI May 11 10:01:51.671 |
| *0     | *0    | *0     | *0     | 3       | 7       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 5.23k   | 64.8k | 16  | rs1  | PRI May 11 10:01:52.672 |
| *0     | *0    | *0     | *0     | 0       | 1       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 157b    | 59.7k | 16  | rs1  | PRI May 11 10:01:53.672 |
| *0     | *0    | *0     | *0     | 0       | 4       | 0     | 0.0% | 0.8%    | 0     | 1.57G | 143M | 0   | 0      | 686b    | 60.8k | 16  | rs1  | PRI May 11 10:01:54.672 |

每秒执行getmore次数

缓存中无效数据所占的百分比

正在使用的缓存百分比

指checkpoint的触发次数在一个轮询间隔期间

虚拟内存使用量，单位是MB

物理内存使用量，单位是MB

集群名

当前已经建立的连接数。

发送端网络速率，单位是bytes

接收端网络速率，单位是bytes

已激活active的读/写次数

队列中waiting的读写次数

## 4.2. mongotop

`./mongotop --host 127.0.0.1 --port 27117`

| ns                     | total | read | write | 2018-05-11T10:47:33+08:00 |
|------------------------|-------|------|-------|---------------------------|
| test.test2             | 39ms  | 0ms  | 39ms  |                           |
| local.oplog.rs         | 38ms  | 38ms | 0ms   |                           |
| admin.\$cmd.aggregate  | 0ms   | 0ms  | 0ms   |                           |
| admin.system.keys      | 0ms   | 0ms  | 0ms   |                           |
| admin.system.roles     | 0ms   | 0ms  | 0ms   |                           |
| admin.system.version   | 0ms   | 0ms  | 0ms   |                           |
| config.system.sessions | 0ms   | 0ms  | 0ms   |                           |
| config.transactions    | 0ms   | 0ms  | 0ms   |                           |
| local.me               | 0ms   | 0ms  | 0ms   |                           |
| local.replset.election | 0ms   | 0ms  | 0ms   |                           |

| - - - ns | total | read | write | 2018-05-11T10:47:34+08:00 |
|----------|-------|------|-------|---------------------------|
|----------|-------|------|-------|---------------------------|

数据库名及集合名

花费在集合上的总时间

执行写操作花费的总时间

执行读操作花费的总时间

## 4.3 Ops Manager




监控集群运行状态，如连接数、每秒查询次数等mongostat相关参数



监控分片使用状态



监控服务器CPU、磁盘空间、IO状态



## 4.4 日志分析

### 1) 启动或禁用分析器

开启 : `db.setProfilingLevel(1,100)`

禁用 : `db.setProfilingLevel(0)`

当前分析器状态 : `db.getProfilingStatus()`

---

### 2) 慢查询

`db.system.profile.find()`

获取长于200ms查询 :

`db.system.profile.find({ "millis" :{$gt:200}}).sort({ "millis" :-1})`

---

### 3) 日志分析工具

mtools 是一组非常好用的 MongoDB 日志分析工具

<https://github.com/rueckstiess/mtools>



## 4.5 执行计划

解析方式：queryPlanner, executionStats和allPlansExecution

```
db.inventory.find(  
  {"flightInfo.oriEng" : "XIY",  
   "flightInfo.desEng" : "SHA",  
   "flightInfo.flightDt" : ISODate("2018-07-  
20T00:00:00.000+08:00")  
}).explain("executionStats")
```

```
"executionStats" : {  
  "executionSuccess" : true,  
  "nReturned" : 10,  
  "executionTimeMillis" : 0,  
  "totalKeysExamined" : 10,  
  "totalDocsExamined" : 10,  
  "executionStages" : {  
    "stage" : "FETCH",  
    "nReturned" : 10,  
    "executionTimeMillisEstimate" : 0,  
    "works" : 11,  
    "advanced" : 10,  
    "needTime" : 0,  
    "needFetch" : 0,  
    "saveState" : 0,  
    "restoreState" : 0,  
    "isEOF" : 1,  
    "invalidates" : 0,  
    "docsExamined" : 10,  
    "alreadyHasObj" : 0,  
    "inputStage" : {  
      "stage" : "IXSCAN",  
      "nReturned" : 10,  
      "executionTimeMillisEstimate" : 0,  
      "works" : 11,  
      "advanced" : 10,  
      "needTime" : 0,  
      "needFetch" : 0,  

```

返回的记录条目

执行时间

扫描的索引条数

实际扫描对象数量

扫描的类型



# 5 性能优化



## 5.1. 索引优化

1

### 提前规划好索引与后台执行

如果在对有数据的集合建索引必须后台执行。

2

### 创建合适的索引

3

### 组合索引字段顺序


组合索引中的字段的顺序：精确匹配—排序—范围查询

4

### 关注应用读/写( read/write) 比率

5

### 确定所有的索引都在RAM中



## 5.2 Kill掉慢请求操作

- ◆ 客户端发起的耗时请求遍历集合、建索引、mapreduce、aggregation等，主动断开连接后，后端的请求仍然执行。
- ◆ killOp通常需要与currentOp组合起来使用；
- ◆ 先根据currentOp查询到请求的opid，然后根据opid发送killOp的请求。




突然正在运行的航班搜索服务接口超时严重？

## 5.3.正确连接复制集


驱动指定多个节点连接复制集，Primary有故障时可自动重新连接。

```
<mongo:mongo id="routeCacheMongo" replica-  
set="dc1shopmdb02.ceair.com:27117,dc1shop-  
mdb01.ceair.com:27117,dc1shopmdb03.ceai-  
r.com:27117">
```



## 5.4.使用长连接

避免使用短连接，多次创建连接关闭连接等操作。






## 5.5 配置合理的连接数

1) 合理设置 thread per connection服务模型。

- 每个线程需要1M的栈空间
- 大量连接时，线程切换开销大

2) Driver通过Connection String URI的maxPoolSize参数来配置连接池大小。





## 5.6.减少返回不必要的内容

1).使用投射 ( projection ) 来减少返回的内容


```
db.getCollection('inv').find({ ""flightInfo.oriEng":"XIY","flightInfo.desEng":"SHA"" }  
,{"flightInfo":1,"_id":0})
```

2).使用skip或limit, 尽可能的减少文档输出。

```
db.getCollection('inv').find({}).skip(10).limit(2)
```

## 5.7 正确使用写关注


| 关注点            | 含义                                                                        |
|----------------|---------------------------------------------------------------------------|
| {w:0}          | 写入不需要Server返回响应。                                                          |
| {w:1}          | 3.x driver默认行为。要求确认操作已经传播到指定的单个mongod实例或副本集主实例，后台默认每100ms保证日志刷盘，每60s数据刷盘。 |
| {w:1 , j:true} | 写入到主实例，并且日志刷盘后向客户端确认。                                                     |
| {w:"majority"} | 写入到已经传递到绝大多数投票节点以及主节点后进行应答。                                               |



在进行写入操作时如何权衡性能与一致性？

## 5.8 正确使用读选项设置

| 关注点                | 含义                                         |
|--------------------|--------------------------------------------|
| primary            | 主节点，默认模式，读操作只在主节点，如果主节点不可用，报错或者抛出异常。       |
| primaryPreferred   | 首选主节点，大多情况下读操作在主节点，如果主节点不可用，如故障转移，读操作在从节点。 |
| secondary          | 从节点，读操作只在从节点，如果从节点不可用，报错或者抛出异常。            |
| secondaryPreferred | 首选从节点，大多情况下读操作在从节点，特殊情况（如单主节点架构）读操作在主节点。   |
| nearest            | 最邻近节点，读操作在最邻近的成员，可能是主节点或者从节点。              |





中國東方航空  
CHINA EASTERN

信 息 部  
IT SOLUTION

关爱 创新 协作 承诺

# 谢谢大家！

