Redis源代码分析

文档审核人	胡戊(huwu)
文档拟制人	邹雨晗(yuhanzou)
文档提交时间	Jun 17, 2011

文档修改记录

文档更新时间	变更内容	变更提出部门	变更理由
Jun 17, 2011	初稿		

目 录

1. Redis介绍 **4**

2. 基本功能 **4**

2.1.* 链表*(adlist.h/adlist.c) ***4***

2.2.* 字符串*(sds.h/sds.c) ***5***

2.3.* 哈希表*(dict.h/dict.c) ***6***

2.4.* 内存*(zmalloc.h/zmalloc.h) ***9***

3. 服务器模型 **11**

3.1.* 事件处理*(ae.h/ae.c) ***11***

3.2.* 套接字操作*(anet.h/anet.c) ***15***

3.3.* 客户端连接*(networking.h/networking.c, redis.c/redis.h) ***15***

3.4.* 命令处理** ***17

4. 虚拟内存 **19**

4.1.* 数据读取过程** ***20

4.2.* 数据交换策略** ***23

5. 备份机制 **24**

5.1. Snapshot ***24***

5.2. AOF ***26***

6. 主从同步 **27**

6.1.* 建立连接** ***27

6.2.* 指令同步** ***30

6.3.* 主从转换** ***31

1. Redis介绍

Redis(http://redis.io)是一个开源的Key-Value存储引擎。它支持string、hash、list、set和sorted set等多种值类型。

2. 基本功能

2.1. 链表(adlist.h/adlist.c)

链表(list)是Redis中最基本的数据结构，由adlist.h和adlist.c定义。

基本数据结构

listNode是最基本的结构，标示链表中的一个结点。结点有向前(next)和向后(prev)连个指针，链表是双向链表。保存的值是void*类型。

```
typedef struct listNode {
    struct listNode *prev;
    struct listNode *next;
    void *value;
} listNode;
```

链表通过list定义，提供头(head)、尾(tail)两个指针，分别指向头部的结点和尾部的结点；提供三个函数指针，供用户传入自定义函数，用于复制(dup)、释放(free)和匹配(match)链表中的结点的值(value)；通过无符号整数len，标示链表的长度。

```
typedef struct list {
    listNode *head;
    listNode *tail;
    void *(*dup)(void *ptr);
    void (*free)(void *ptr);
    int (*match)(void *ptr, void *key);
    unsigned int len;
} list;
```

listIter是访问链表的迭代器，指针(next)指向链表的某个结点，direction标示迭代访问的方向(宏AL_START_HEAD表示向前，AL_START_TAIL表示向后）。

```
typedef struct listIter {
    listNode *next;
    int direction;
} listIter;
```

使用方法

Redis定义了一系列的宏，用于访问list及其内部结点。

链表创建时(listCreate)，通过Redis自己实现的zmalloc()分配堆空间。链表释放(listRelease)或删除结点(listDelNode)时，如果定义了链表(list)的指针函数free，Redis会使用它释放链表的每一个结点的值(value)，否则需要用户手动释放。结点的内存使用Redis自己实现的zfree()释放。

对于迭代器，通过方法listGetIterator()、listNext()、listReleaseIterator()、listRewind()和listRewindTail()使用，例如对于链表list，要从头向尾遍历，可通过如下代码:

```
iter = listGetIterator(list, AL_START_HEAD); // 获取迭代器
```

```
while((node = listNext(iter)) != NULL) {
    DoItWithValue(listNodeValue(node)); // 用户实现DoItWithValue
}
listReleaseIterator(iter);
```

listDup()用于复制链表，如果用户实现了dup函数，则会使用它复制链表结点的value。listSearchKey()通过循环的方式在O(N)的时间复杂度下查找值，若用户实现了match函数，则用它进行匹配，否则使用按引用匹配。

2.2. 字符串(sds.h/sds.c)

字符串是Redis中最基本的数据。Redis使用key作为存取value的唯一标示符，而key的通俗理解就是字符串。Redis中的字符串分为两类：二进制安全(Binary Safe)和非二进制安全。二进制安全的字符串，是指字符串中所有字符均可用256个字符(8bit)编码[2]。Redis中的value都是通过二进制安全的字符串存储的，而key使用的是非二进制安全的。

基本数据结构

Redis内部实现了字符串类型，由sds.h和sds.c定义。

sds本质是char*：

```
typedef char *sds;
```

通过sdsnewlen()创建时，Redis内部会创建sdshdr结构，这个结构的定义如下，其中len表示字符串的实际长度，free表示可以额外使用的字节数。sdshdr分配的内存空间，为sizeof(int)+sizeof(int)+sizeof(char*)+len+free。

```
struct sdshdr {
    int len;
    int free;
    char buf[];
};
```

在sdsnewlen(const void *init, size_t initlen)中，会分配sizeof(struct sdshdr)+initlen+1的空间，并将*init指向的字符串拷贝到buf中，在buf末尾补上'\0'。但是sdsnewlen()中返回给外部的，只有sdshdr->buf。

假如用户调用了sdsnewlen("qqmail", 6)，则64位系统中，Redis会分配24 + 6+1字节的空间，在内存中的结构如下：

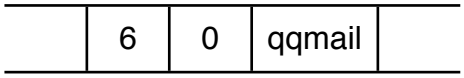

返回给用户的sdshdr->buf，指向内存中"qqmail"的起点，想通过buf获得指向sdshdr的指针是很容易的，例如方法sdslen()中：

```
size_t sdslen(const sds s) {
    struct sdshdr *sh = (void*) (s-(sizeof(struct sdshdr)));
    return sh->len;
}
```

通过(s-(sizeof(struct sdshdr))即可得到sdshdr的地址。

使用方法

了解了sdshdr的结构之后，理解相关的方法就很容易了。而Redis这样仅暴露buf的做法，使得应用程序可以将sds简单地当成char*使用。

创建sds的方法有：

```
sds sdsnewlen(const void *init, size_t initlen);
sds sdsnew(const char *init);
sds sdsempty();
```

三个方法均用zmalloc()分配内存空间，sdsempty()创建空字符串。void sdsfree(sds s)用于释放字符串。size_t sdslen(const sds s)会返回字符串的总长度。而size_t sdsavail(sds s)返回字符串中可用的字节数。以下几个函数会涉及sds内存空间的分配：

```
sds sdsgrowzero(sds s, size_t len);
sds sdscatlen(sds s, void *t, size_t len);
sds sdscat(sds s, char *t);
sds sdscpylen(sds s, char *t, size_t len);
sds sdscpy(sds s, char *t);
```

其中sdsgrowzero()会增加sds的内存空间，并用'\0'填充，用free记录空余空间。sdscat()将字符串t连接在s的尾部，sdscpy()将字符串t复制到s中。若s中空间不够时，会调用sdsgrowzero()分配更多内存。

此外，sds还提供了一些字符串相关的操作函数，在此不详细分析。

2.3. 哈希表(dict.h/dict.c)

Redis的哈希表最大的特色就是自动扩容。当它的哈希表容量不够时，可以0/1切换，然后自动扩容。下面具体分析哈希表的实现。

整个哈希系统由结构体dict定义，其中type包含一系列哈希表需要用的函数，dictht类型的数组ht[2]表示两个哈希表实例，由rehashidx指明下一个需要扩容的哈希实例的编号，iterators记录外部使用哈希表的迭代器的数目。

```
typedef struct dict {
    dictType *type;
    void *privdata;
    dictht ht[2];
    int rehashidx; /* rehashing not in progress if rehashidx == -1 */
    int iterators; /* number of iterators currently running */
} dict;
```

dictht为哈希表具体实现的结构体，table指向哈希中的记录，用数组+开链的形式保存记录；size表示哈希表桶的大小，为2的指数；sizemark=size-1，方便哈希值根据size取模；used记录了哈希表中的记录数目。

```
typedef struct dictht {
    dictEntry **table;
    unsigned long size;
    unsigned long sizemask;
    unsigned long used;
} dictht;
```

哈希表使用开链的方式处理冲突，每条记录都是链表中的一个结点。dictType在哈希系统中包含了一系列可由应用程序定义的函数指针，包括Hash函数、Key复制、Value复制、Key比较、Key析构、Value析构，以增加哈希系统的灵活性。 其中系统定义了三种默认的type，表示最常用的三种哈希表。

```
typedef struct dictType {
    unsigned int (*hashFunction)(const void *key);
    void *(*keyDup)(void *privdata, const void *key);
```

```
    void *(*valDup)(void *privdata, const void *obj);
    int (*keyCompare)(void *privdata, const void *key1, const void *key2);
    void (*keyDestructor)(void *privdata, void *key);
    void (*valDestructor)(void *privdata, void *obj);
} dictType;
extern dictType dictTypeHeapStringCopyKey;
extern dictType dictTypeHeapStrings;
extern dictType dictTypeHeapStringCopyKeyValue;
```

Redis定义了一系列的宏用于操作哈希表，例如设置记录的Value。对外提供的API，除了常规的创建哈希表，增、删、改记录之外，有两类是比较特别的：自动扩容和迭代器。

自动扩容

Redis用变量dict_can_resize记录哈希是否可以自动扩容，由两个方法dictEnableResize()和dictDisableResize()设置该变量。

应用程序可以使用dictResize()扩容，它首先判断是否允许扩容，及是否正在扩容。若可以扩容，则调用dictExpand()扩容。然后应用程序需要调用dictRehashMilliseconds()启动扩容过程，并指定扩容过程中记录拷贝速度。

除了应用程序指定的扩容外，在调用dictAdd()往哈希中添加记录时，系统也会通过调用_dictExpandIfNeeded()判断是否需要扩容。_dictExpandIfNeeded（）中，如果正在扩容，则不会重复进行扩容；如果哈希表size = 0，即桶数目为0，则扩容到初始大小；否则如果used>=size，并且can_resize==1或used/size超过阀值（默认为5）时，以max(used, size)的两倍为基数，调用dictExpand()扩容。

```
    if (dictIsRehashing(d)) return DICT_OK;
    if (d->ht[0].size == 0) return dictExpand(d, DICT_HT_INITIAL_SIZE);

    if (d->ht[0].used >= d->ht[0].size &&
        (dict_can_resize ||
         d->ht[0].used/d->ht[0].size > dict_force_resize_ratio))
    {
        return dictExpand(d, ((d->ht[0].size > d->ht[0].used) ?
                                    d->ht[0].size : d->ht[0].used)*2);
    }
    return DICT_OK;
```

dictExpand()进行扩容时，会先选择一个满足size需求的2的指数，然后分配内存空间，创建新的哈希表。如果此时ht[0]为空，则直接将哈希表赋值给ht[0]；否则，赋值给ht[1]，并启动拷贝过程，将ht[0]的记录逐个桶地拷贝到ht[1]中。置rehashidx=0，表明正在扩容，且待拷贝的桶为ht[0]->table[rehashidx]。

```
    dictht n; /* the new hashtable */
    unsigned long realsize = _dictNextPower(size);

    if (dictIsRehashing(d) || d->ht[0].used > size)
        return DICT_ERR;

    n.size = realsize;
    n.sizemask = realsize-1;
    n.table = zcalloc(realsize*sizeof(dictEntry*));
    n.used = 0;

    if (d->ht[0].table == NULL) {
        d->ht[0] = n;
```

```
        return DICT_OK;
    }

    d->ht[1] = n;
    d->rehashidx = 0;
    return DICT_OK;
```

dictIsRehashing()通过rehashidx来判断是否正在扩容。这个方法在多处被调用，当dictAdd()往哈希表中添加记录时，也会通过该方法判断是否正在扩容。若正在扩容，则调用_dictRehashStep()，该函数判断，若此时iterators==0，即没有迭代器时，就从ht[0]中拷贝一部分记录到ht[1]。

拷贝过程在dictRehash()中完成，该函数返回0时，表示扩容结束，ht[0]中所有记录都已拷贝到ht[1]，且rehashidx被置为-1；否则返回1，表示扩容未结束。拷贝过程中，将ht[0]->table[rehashidx]拷贝到ht[1]后，rehashidx++，直到used==0，即所有记录拷贝完成。拷贝一个桶时，需要对桶中所有元素重新求哈希值，然后一个个放入ht[1]中。dictRehash()通过参数，控制每次拷贝的桶的数目。该过程由下面代码描述：

```
int dictRehash(dict *d, int n) {
    if (!dictIsRehashing(d)) return 0;

    while(n--) {
        dictEntry *de, *nextde;

        if (d->ht[0].used == 0) {
            zfree(d->ht[0].table);
            d->ht[0] = d->ht[1];
            _dictReset(&d->ht[1]);
            d->rehashidx = -1;
            return 0;
        }

        while(d->ht[0].table[d->rehashidx] == NULL) d->rehashidx++;
        de = d->ht[0].table[d->rehashidx];

        while(de) {
            unsigned int h;

            nextde = de->next;
            /* Get the index in the new hash table */
            h = dictHashKey(d, de->key) & d->ht[1].sizemask;
            de->next = d->ht[1].table[h];
            d->ht[1].table[h] = de;
            d->ht[0].used--;
            d->ht[1].used++;
            de = nextde;
        }
        d->ht[0].table[d->rehashidx] = NULL;
        d->rehashidx++;
    }
    return 1;
}
```

迭代器

迭代器提供了遍历哈希表中所有元素的方法，通过dictGetIterator()获得迭代器后，使用dictNext(dictIterator *)方法获得下一个元素。当外部持有的迭代器数目不为0时，哈希表会暂停扩容操作。

迭代器遍历的过程，从ht[0]开始，依次从第一个桶table[0]开始遍历桶中的元素，然后时table[1], table[2], ..., table[size]，若正在扩容，则会继续遍历ht[1]中的桶。遍历桶中元素时，依次访问链表中的每个元素。

2.4. 内存(zmalloc.h/zmalloc.h)

前文已提到，Redis通过自己的方法管理内存,，主要方法有zmalloc(), zrealloc()，zcalloc()和zfree(), 分别对应C中的malloc(), realloc()、calloc()和free()。相关代码在zmalloc.h和zmalloc.c中。

Redis自己管理内存的好处主要有两个：可以利用内存池等手段提高内存分配的性能；可以掌握更多的内存信息，以便于Redis虚拟内存(VM)等功能中，决定何时将数据swap到磁盘。

先回忆各个系统中常见的内存分配函数：

malloc()分配一块指定大小的内存区域，并返回指向区域开头的指针，若分配失败，则返回NULL。

calloc()与malloc()一样，分配一块指定大小的内存区域，成功时返回区域头指针，失败返回NULL。区别在于，calloc()的输入参数为count和size，即分配的项的数目，及每一项的大小。calloc()在成功分配内存空间后，会将空间内所有值置0。

realloc()修改已分配的内存块的大小。若已分配的内存块后没有足够的空间用于扩展内存块，则重新申请一块满足需要的内存块，并将旧的数据拷贝到新位置，释放旧的内存块，返回指向新的内存块的指针；否则直接扩展原有的内存块。若分配失败，返回NULL。

free()释放已分配的内存块。

内存分配

在Redis中，如果系统中包含TCMALLOC，则会使用tc_malloc()等TCMALLOC中的方法代替malloc()等原有的分配内存方法。TCmalloc是google perftools中的一个组件。

```
#if defined(USE_TCMALLOC)
#define malloc(size) tc_malloc(size)
```

首先看zmalloc()和zfree()两个最常用的方法。Redis在申请内存时，除了申请需要的size外，还会多申请一块定长(PREFIX_SIZE)的区域用于记录所申请的内存块的长度。如果申请成功，Redis会使用宏函数（Redis中为性能考虑，大量使用宏函数）update_zmalloc_stat_alloc(size+PREFIX_SIZE, size)记录申请的内存块的相关信息，以便监控内存使用状况；当内存块被zfree()释放时，根据头部的信息可以快速地获知被释放的内存区域的长度，然后通过宏函数update_zmalloc_stat_free()标记释放。源代码中，若系统支持malloc_size()方法，则会使用它返回指针所指向的内存块的大小（Mac OS X 10.4以上支持该方法[3]）。有疑惑的是，在支持malloc_size()的系统中，为何还要多申请PREFIX_SIZE的内存?

```
void *zmalloc(size_t size) {
    void *ptr = malloc(size+PREFIX_SIZE);

    if (!ptr) zmalloc_oom(size);
#ifdef HAVE_MALLOC_SIZE
    update_zmalloc_stat_alloc(redis_malloc_size(ptr),size);
    return ptr;
#else
    *((size_t*)ptr) = size; // 在头部记录内存块的长度
    update_zmalloc_stat_alloc(size+PREFIX_SIZE,size);
    return (char*)ptr+PREFIX_SIZE;
#endif
}
```

宏update_zmalloc_stat_alloc()中，首先将要分配的空间与内存对齐，然后会根据宏zmalloc_thread_safe判断是否需要对内存信息记录表的相关操作加锁。虽然Redis在大部分场景中是单线程读写的，即thread_safe的，但启用虚拟内存(VM)，或持久化dump到磁盘等操作时会启动多线程，因此在多线程模式中，需要对部分操作加锁。

内存监控

used_memory记录了Redis使用的内存总数。而多线程下malloc()是线程安全的。zmalloc_allocations[]记录了各个size分配的内存块的数目，大于256个字节的按256算。应用程序可以通过zmalloc_allocations_for_size(size)获得对应size的内存块的分配数目；也可以通过zmalloc_used_memory()获得Redis占用的总内存。这些监控类的方法在Redis的日志系统中被用到。

```
#define update_zmalloc_stat_alloc(__n,__size) do { \
    size_t _n = (__n); \
    size_t _stat_slot = (__size < ZMALLOC_MAX_ALLOC_STAT) ? __size :
ZMALLOC_MAX_ALLOC_STAT; \
    if (_n&(sizeof(long)-1)) _n += sizeof(long)-(_n&(sizeof(long)-1)); \
    if (zmalloc_thread_safe) { \
        pthread_mutex_lock(&used_memory_mutex);  \
        used_memory += _n; \
        zmalloc_allocations[_stat_slot]++; \
        pthread_mutex_unlock(&used_memory_mutex); \
    } else { \
        used_memory += _n; \
        zmalloc_allocations[_stat_slot]++; \
    } \
} while(0)
```

外部应用程序通过zmalloc_enable_thread_safeness()方法开启Redis内存模块的线程安全模式，后文会分析哪些功能需要开启线程安全。

zcalloc(size)、zrealloc()与zmalloc()的处理策略类似，不再详述。

在部分操作系统中，Redis可以通过zmalloc_get_rss()方法获得自己的进程占用的内存信息。该信息通过操作系统提供，往往比Redis自己记录的used_memory更准确，但其获取速度也较慢。这些信息也是用于虚拟内存功能。

除了内存相关的操作外，Redis在此还提供了一个复制字符串的方法zstrdup(char *)，该方法将申请一块与源字符串长度相同的内存区域，并用memcpy()拷贝字符串的内容。

3. 服务器模型

3.1. 事件处理(ae.h/ae.c)

Redis是单线程模型（虚拟内存等功能会启动其它线程(进程)），通过事件机制异步地处理所有请求。

Redis的事件模型在不同的操作系统中提供了不同的实现，ae_epoll.h/ae_epoll.c为epoll的实现，ae_select.h/ae_select.c是select的实现，ae_kqueue.h/ae_kqueue.c是bsd中kqueue的实现。

基本事件

Redis提供两种基本事件：FileEvent和TimeEvent。前者是基于操作系统的异步机制(epoll/kqueue)实现的文件事件，后者是Redis自己实现的定时器。

aeEventLoop是事件模型中最基本的结构体：

```
typedef struct aeEventLoop {
    int maxfd;
    long long timeEventNextId;
    aeFileEvent events[AE_SETSIZE]; /* Registered events */
    aeFiredEvent fired[AE_SETSIZE]; /* Fired events */
    aeTimeEvent *timeEventHead;
    int stop;
    void *apidata; /* This is used for polling API specific data */
    aeBeforeSleepProc *beforesleep;
} aeEventLoop;
```

maxfd标示当前最大的事件描述符。events和fired分别保存了已注册和已注销的FileEvent，AE_SETSIZE是Redis中可以注册的事件的上限，默认为1024*10。timeEventHead指向一个TimeEvent的链表，timeEventNextId标示下一个定时器。beforesleep是每次事件轮询前都会执行的函数，相当于hook。stop用于停止事件轮询。

```
typedef struct aeFileEvent {
    int mask; /* one of AE_(READABLE|WRITABLE) */
    aeFileProc *rfileProc;
    aeFileProc *wfileProc;
    void *clientData;
} aeFileEvent;
```

aeFileEvent可以用于socket事件的监听。mask表示要监听的事件类型，rfileProc和wfileProc分别为读事件和写事件的响应函数。clientData。

```
typedef struct aeTimeEvent {
    long long id; /* time event identifier. */
    long when_sec; /* seconds */
    long when_ms; /* milliseconds */
    aeTimeProc *timeProc;
    aeEventFinalizerProc *finalizerProc;
    void *clientData;
    struct aeTimeEvent *next;
} aeTimeEvent;
```

aeTimeEvent用于定时器(timer)，其实现是一个链表，其中每一个结点是一个timer，并有独立id。when_sec和when_ms指定了定时器的触发时间，timeProc为响应函数，finalizerProc为删除定时器时的“析构函数”。

aeFiredEvent表示触发的FileEvent，其中fd为文件描述符，mask为事件类型。

相关操作

Redis提供了一系列的API用于操作事件。aeCreateEventLoop()和aeDeleteEventLoop(aeEventLoop*)分别用于初始化和删除事件循环。初始化eventLoop时，会初始化对应操作系统的实现，例如Linux中会使用ae_epoll.c中的aeApiCreate()初始化事件使用的文件描述符和事件列表。Redis中使用了三个宏AE_NONE、AE_READABLE和AE_WRITABLE表示监听的FileEvent的类型，初始时eventLoop中所有events的监听类型为AE_NONE。aeStop(aeEventLoop*)用户暂停事件轮询。

aeCreateFileEvent()和aeDeleteFileEvent()用于创建和删除FileEvent，在Linux系统中，会使用epoll监听文件描述符，并用EPOLLIN和EPOLLOUT监听文件的Read和Write事件，并在eventLoop->apiData中记录相关信息。

aeCreateTimeEvent()和aeDeleteTimeEvent()用于创建和删除TimeEvent。

aeMain(aeEventLoop*)是启动事件轮询的入口，内部实现是一个死循环，每一次循环中先执行eventLoop->beforesleep()方法，然后使用aeProcessEvents()轮询事件。aeProcessEvents()中，首先找到最近的timer（最先超时的），记下距该timer触发的时间，并作为检查FileEvent的超时时间。Redis通过不同操作系统实现(Linux:ae_epoll.c)中的aeApiPoll()方法，检查是否触发了FileEvent，若触发则根据mask决定响应函数(rfileProc/wfileProc)。FileEvent的优先级高于TimeEvent，因此可以将TimerEvent的触发时间用作FileEvent轮询的超时时间。

检查完FileEvent后，通过调用processTimeEvents()检查TimeEvent，触发所有已超时的timer的timeProc，根据timeProc的返回值，决定是删除timer还是继续增加timer的触发时间。例如，timeProc返回100时，则将timer的触发时间增加100ms，即100ms后再次触发该timer。若timeProc一直返回100，则该timer会每隔100ms触发一次。其中重要代码如下：

```
...
retval = te->timeProc(eventLoop, id, te->clientData);
processed++;
if (retval != AE_NOMORE) {
    aeAddMillisecondsToNow(retval,&te->when_sec,&te->when_ms);
} else {
    aeDeleteTimeEvent(eventLoop, id);
}
...
```

除了上述异步的事件机制外，Redis还提供了一个同步处理事件的API：aeWait(int fd, int mask, long long mileseconds)，fd指明了需要监听的文件描述符，mask说明监听的事件类型，mileseconds指明超时事件。该方法内部通过select实现了阻塞型等待。

Redis提供aeSetBeforeSleepProc()用于设置事件轮询中每次循环前执行的方法。

初始化事件轮询

Redis启动时便会初始化事件轮询并启动，int main()中，调用initServer()初始化服务端。在initServer()中，初始化事件轮询，通过TimeEvent定制一个定时器

serverCron，每100ms执行一次服务器相关的操作。在Redis所有初始化工作完成后，执行aeMain()启动事件轮询。

```
int initServer() {
    // ...
    server.el = aeCreateEventLoop();
    // ...
}
int main(int argc, char **argv) {
    // ...
    initServer();
    // ....
    aeSetBeforeSleepProc(server.el,beforeSleep);
    aeMain(server.el);
    aeDeleteEventLoop(server.el);
}
```

事件系统在处理TimeEvent和FileEvent之前，会调用BeforeSleepProc，Redis中事件循环前会调用beforeSleep()。该函数负责许多功能，例如处理已经ready的客户端连接，处理虚拟内存的换入换出机制，处理aof等等。

serverCron()是Redis中非常重要的函数，负责协调Redis中许多功能。首先更新全局的时间戳server.unixtime，Redis中各个模块中对时间要求不严格的地方，均通过这个时间戳获取系统时间，以避免调用time(NULL)的时间消耗。然后更新虚拟内存换入换出策略相关的时间戳server.lruclock。

```
    /* We take a cached value of the unix time in the global state because
     * with virtual memory and aging there is to store the current time
     * in objects at every object access, and accuracy is not needed.
     * To access a global var is faster than calling time(NULL) */
    server.unixtime = time(NULL);
    /* We have just 22 bits per object for LRU information.
     * So we use an (eventually wrapping) LRU clock with 10 seconds resolution.
     * 2^22 bits with 10 seconds resoluton is more or less 1.5 years.
     *
     * Note that even if this will wrap after 1.5 years it's not a problem,
     * everything will still work but just some object will appear younger
     * to Redis. But for this to happen a given object should never be touched
     * for 1.5 years.
     *
     * Note that you can change the resolution altering the
     * REDIS_LRU_CLOCK_RESOLUTION define.
     */
    updateLRUClock();
```

然后，如果收到SIGTERM信息，会停止服务器。然后打印一些数据库相关的运行日志。当没有后台的虚拟内存控制进程和备份进程时，会尝试对哈希表进行扩容。

```
    /* We don't want to resize the hash tables while a bacground saving
     * is in progress: the saving child is created using fork() that is
     * implemented with a copy-on-write semantic in most modern systems, so
     * if we resize the HT while there is the saving child at work actually
     * a lot of memory movements in the parent will cause a lot of pages
     * copied. */
    if (server.bgsavechildpid == -1 && server.bgrewritechildpid == -1) {
        if (!(loops % 10)) tryResizeHashTables();
        if (server.activerehashing) incrementallyRehash();
    }
```

然后输出客户端连接的相关数据日志，并关闭超时连接。再次检查，如果有后台进程在进行备份，则等待它们完成，并进行一些清理，然后开始执行哈希表扩容。如果没有上述后台进程，则判断是否需要进行备份。

```
    /* Check if a background saving or AOF rewrite in progress terminated */
    if (server.bgsavechildpid != -1 || server.bgrewritechildpid != -1) {
        int statloc;
        pid_t pid;

        if ((pid = wait3(&statloc,WNOHANG,NULL)) != 0) {
            if (pid == server.bgsavechildpid) {
                backgroundSaveDoneHandler(statloc);
            } else {
                backgroundRewriteDoneHandler(statloc);
            }
            updateDictResizePolicy();
        }
    } else {
        /* If there is not a background saving in progress check if
         * we have to save now */
         time_t now = time(NULL);
         for (j = 0; j < server.saveparamslen; j++) {
            struct saveparam *sp = server.saveparams+j;

            if (server.dirty >= sp->changes &&
                now-server.lastsave > sp->seconds) {
                redisLog(REDIS_NOTICE,"%d changes in %d seconds. Saving...",
                    sp->changes, sp->seconds);
                rdbSaveBackground(server.dbfilename);
                break;
            }
         }
    }
```

若服务器为master，则释放过期的key；若为slave，则等待同步指令DEL。

```
    /* Expire a few keys per cycle, only if this is a master.
     * On slaves we wait for DEL operations synthesized by the master
     * in order to guarantee a strict consistency. */
    if (server.masterhost == NULL) activeExpireCycle();
```

然后检查物理内存使用率，若超过阀值，则将部分不常用的Entity换出到磁盘。Redis的虚拟内存的换入换出机制分两种，根据server.vm_max_threads设置分别使用不同的机制。

```
    /* Swap a few keys on disk if we are over the memory limit and VM
     * is enbled. Try to free objects from the free list first. */
    if (vmCanSwapOut()) {
        while (server.vm_enabled && zmalloc_used_memory() >
                server.vm_max_memory)
        {
            int retval = (server.vm_max_threads == 0) ?
                        vmSwapOneObjectBlocking() :
                        vmSwapOneObjectThreaded();
            if (retval == REDIS_ERR && !(loops % 300) &&
                zmalloc_used_memory() >
                (server.vm_max_memory+server.vm_max_memory/10))
            {
                redisLog(REDIS_WARNING,"WARNING: vm-max-memory limit exceeded by
more than 10%% but unable to swap more objects out!");
            }
```

```
            /* Note that when using threade I/O we free just one object,
             * because anyway when the I/O thread in charge to swap this
             * object out will finish, the handler of completed jobs
             * will try to swap more objects if we are still out of memory. */
            if (retval == REDIS_ERR || server.vm_max_threads > 0) break;
        }
    }
```

最后，若服务器为slave，则每10次serverCron（即1秒）检查一次与master的连接式否正常。

```
/* Replication cron function -- used to reconnect to master and
     * to detect transfer failures. */
    if (!(loops % 10)) replicationCron();
```

```
    // Todo slave不正常
```

3.2. 套接字操作(anet.h/anet.c)

Redis在anet.h/c中封装了所有底层套接字操作：

```
int anetTcpConnect(char *err, char *addr, int port);
int anetTcpNonBlockConnect(char *err, char *addr, int port);
int anetUnixConnect(char *err, char *path);
int anetUnixNonBlockConnect(char *err, char *path);
int anetRead(int fd, char *buf, int count);
int anetResolve(char *err, char *host, char *ipbuf);
int anetTcpServer(char *err, int port, char *bindaddr);
int anetUnixServer(char *err, char *path);
int anetTcpAccept(char *err, int serversock, char *ip, int *port);
int anetUnixAccept(char *err, int serversock);
int anetWrite(int fd, char *buf, int count);
int anetNonBlock(char *err, int fd);
int anetTcpNoDelay(char *err, int fd);
int anetTcpKeepAlive(char *err, int fd);
```

anetTcpServer()是建立网络套接字服务器的方法，即对socket()、bind()、listen()等一系列操作的封装，并返回socket的fd。anetUnixServer()建立本地套接字服务器。

anetTcpConnect()、anetTcpNonBlockConnect()用于建立阻塞型和非阻塞型网络套接字连接。anetUnixConnect()、anetUnixNonBlockConnect()用于建立阻塞型和非阻塞型的本地套接字连接。

anetNonBlock()将一个fd设置为非阻塞型。anetTcpNoDelay()将TCP连接设为非延迟的，即屏蔽Nagle算法。anetTcpKeepAlive()开启连接检测，避免对方宕机、网络中断时fd永远阻塞。

anetRead()和anetWrite()用于套接字上的读写功能，anetTcpAccept()和anetUnixAccept()分别在网络套接字和本地套接字上新增连接。

Redis通过这些API封装了所有套接字操作，但这些操作并没有什么特别之处，不再详细分析其实现。

3.3. 客户端连接(networking.h/networking.c, redis.c/redis.h)

本节关注Redis的并发框架，及客户端连接的建立和请求处理。上述事件模型，及网络操作，拼凑出Redis的服务器并发框架。

初始化服务器

main()中先调用initServerConfig()初始化服务器配置。包括端口、物理文件等基本信息，虚拟内存的各种设置，及command table(server.commands)等。前文已说过，Redis的dict支持自定义各种行为（例如Hash函数，比较函数等），初始化command table时，首先用commandTableDictType指定将command dict的各种行为，然后populateCommand()初始化各种命令。Redis中命令由结构体redisCommand定义，后文分析。这里，Redis会将一系列的命令载入command table中。

然后main()调用initServer()初始化事件轮询，紧接着会调用anetTcpServer()初始化服务器。

```
initServer() {
    // ....
    server.ipfd = anetTcpServer(server.neterr,server.port,server.bindaddr);
    // ...
    if (server.ipfd > 0 && aeCreateFileEvent(server.el,server.ipfd,AE_READABLE,
acceptTcpHandler,NULL) == AE_ERR) oom("creating file event");
    // ...
}
```

完成服务器的初始化后，Redis已开始监听端口，通过aeCreateFileEvent()监听端口的READABLE事件，若该事件触发，则表示有新连接建立。acceptTcpHandler()响应READABLE事件，调用anetTcpAccept()建立连接，获得客户端连接的fd。获得fd后，通过createClient()方法，创建连接相关信息，保存在结构体redisClient中。该结构体保存了连接的fd，输入buf，输出buf等一系列的信息。 Redis在处理请求时完全是用单线程异步模式，通过epoll监听所有连接的读写事件，并通过相应的响应函数处理。Redis使用这样的设计来满足需求，很大程度上因为它服务的是高并发的短连接，且请求处理事件非常短暂。这个模型下，一旦有请求阻塞了服务，整个Redis的服务将受影响。Redis采用单线程模型可以避免系统上下文切换的开销。

Redis的连接由结构体redisClient(redis.h)定义，默认使用非阻塞、非延迟型的连接。连接由createClient()方法创建，由freeClient()方法释放。createClient()的过程中，在连接的fd上监听READABLE事件，当该事件触发时说明接收到客户端请求，调用readQueryFromClient()方法处理请求。然后初始化连接的输入缓冲区，参数列表等等。最后将连接加入全局的连接列表server.clients中。

```
/* With multiplexing we need to take per-clinet state.
 * Clients are taken in a liked list. */
typedef struct redisClient {
    int fd;
    redisDb *db;
    int dictid;
    sds querybuf;
    int argc;
    robj **argv;
    int reqtype;
    int multibulklen;       /* number of multi bulk arguments left to read */
    long bulklen;           /* length of bulk argument in multi bulk request */
    list *reply;
    int sentlen;
    time_t lastinteraction; /* time of the last interaction, used for timeout 最
后一次交互的时间戳*/
    int flags;              /* REDIS_SLAVE | REDIS_MONITOR | REDIS_MULTI ... 连
接的状态标记，初始时为0 */
```

```
    int slaveseldb;         /* slave selected db, if this client is a slave */
    int authenticated;      /* when requirepass is non-NULL */
    int replstate;          /* replication state if this is a slave */
    int repldbfd;           /* replication DB file descriptor */
    long repldboff;         /* replication DB file offset */
    off_t repldbsize;       /* replication DB file size */
    multiState mstate;      /* MULTI/EXEC state */
    blockingState bpop;   /* blocking state */
    list *io_keys;          /* Keys this client is waiting to be loaded from the
                             * swap file in order to continue. */
    list *watched_keys;     /* Keys WATCHED for MULTI/EXEC CAS */
    dict *pubsub_channels;  /* channels a client is interested in (SUBSCRIBE) */
    list *pubsub_patterns;  /* patterns a client is interested in (SUBSCRIBE) */

    /* Response buffer */
    int bufpos;
    char buf[REDIS_REPLY_CHUNK_BYTES];
} redisClient;
```

以下几种情况会使用freeClient()释放连接：从客户端读数据错误、已到达服务器最大连接数(server.maxclients)、

客户端的状态标记中，有三个状态会让Redis不再处理客户端命令：REDIS_BLOCKED（处理阻塞操作）和REDIS_IO_WAIT（等待虚拟内存）会让客户端读入数据后阻塞，不处理命令。REDIS_CLOSE_AFTER_REPLY标记会让客户端输出数据后立即关闭，此时也不再处理输入的命令。

3.4. 命令处理

Redis的命令由结构体redisCommand定义，包含了指向命令处理函数的指针。

```
typedef void redisCommandProc(redisClient *c);
typedef void redisVmPreloadProc(redisClient *c, struct redisCommand *cmd, int
argc, robj **argv);
struct redisCommand {
    char *name;
    redisCommandProc *proc;
    int arity;
    int flags;

    redisVmPreloadProc *vm_preload_proc;

    int vm_firstkey;
    int vm_lastkey;
    int vm_keystep;
};
```

Redis在readQueryFromClient()中处理客户端的Input，每次尝试读取长度为REDIS_IOBUF_LEN（默认为1024）的数据，输入的数据保存在redisClient结构体的querybuf中sdscatlen(c->querybuf,buf,nread)，然后调用processInputBuffer()处理数据。

若客户端处于ready状态（即flags中无REDIS_BLOCKED、REDIS_IO_WAIT和REDIS_CLOSE_AFTER_REPLY）状态，则尝试处理输入数据。若客户端没有通过reqtype指定使用的协议，则根据数据的第一个字节判断，若querybuf[0]=='*'，则使用MULTIBULK协议，否则为INLINE协议，分别调用对应的协议解包函数并处理命令，完成后重置客户端(resetClient())。

```
void processInputBuffer(redisClient *c) {
    while(sdslen(c->querybuf)) {
        if (c->flags & REDIS_BLOCKED || c->flags & REDIS_IO_WAIT) return;
        if (c->flags & REDIS_CLOSE_AFTER_REPLY) return;

        if (!c->reqtype) {
            if (c->querybuf[0] == '*') {
                c->reqtype = REDIS_REQ_MULTIBULK;
            } else {
                c->reqtype = REDIS_REQ_INLINE;
            }
        }

        if (c->reqtype == REDIS_REQ_INLINE) {
            if (processInlineBuffer(c) != REDIS_OK) break;
        } else if (c->reqtype == REDIS_REQ_MULTIBULK) {
            if (processMultibulkBuffer(c) != REDIS_OK) break;
        } else {
            redisPanic("Unknown request type");
        }

        if (c->argc == 0) {
            resetClient(c);
        } else {
            if (processCommand(c) == REDIS_OK)
                resetClient(c);
        }
    }
}
```

INLINE协议非常简单，按换行符(‘\r\n’)分隔，一行是一条命令。命令中参数用空格分隔，通过processInlineBuffer()解析后，存放在argc/argv中，其中argv是redisObject对象的数组。

MULTIBULK协议 //TODO

processCommand()中处理所有客户端的命令。首先是”quit”，Redis接收到这个命令后将客户端连接断开；否则，使用lookupCommand()从command table中查找命令，然后通过命令的处理函数(cmd->proc())处理命令。

以‘get’命令为例，它在readonlyCommandTable中定义，在initServerConfig()初始化过程中载入command table，若服务器接收到get命令，则通过lookupCommand()找到对应的redisCommand结构体的实例，通过处理函数getCommand()处理命令。

```
struct redisCommand readonlyCommandTable[] = {
    {"get",getCommand,2,0,NULL,1,1,1},
    // ....
}
```

redis将命令处理函数的实现写在t_***.c中，例如t_string.c实现了字符串操作相关的命令，包括getCommand()。

4. 虚拟内存

虚拟内存是Redis中最复杂的模块，它几乎影响了Redis所有模块的功能。Redis作为一个内存数据库，数据量受内存制约，为了存储更多的数据，Redis在2.0加入了虚拟内存功能，允许将不常访问的数据的value放入磁盘中。

虚拟内存部分的分析分为两部分：获取在vm中的数据的过程，数据在vm中换入换出策略。分析前者前，先看Redis为支持虚拟内存的数据结构。

Redis底层用结构体redisObject表示保存的数据项。

```
/* The actual Redis Object */
#define REDIS_LRU_CLOCK_MAX ((1<<21)-1) /* Max value of obj->lru */
#define REDIS_LRU_CLOCK_RESOLUTION 10 /* LRU clock resolution in seconds */
typedef struct redisObject {
    unsigned type:4;
    unsigned storage:2;     /* REDIS_VM_MEMORY or REDIS_VM_SWAPPING */
    unsigned encoding:4;
    unsigned lru:22;        /* lru time (relative to server.lruclock) */
    int refcount;
    void *ptr;
    /* VM fields are only allocated if VM is active, otherwise the
     * object allocation function will just allocate
     * sizeof(redisObjct) minus sizeof(redisObjectVM), so using
     * Redis without VM active will not have any overhead. */
} robj;
```

其中type表示value的数据类型：string、list、set；storage表示存储的位置， Redis共定义了四种存储状态，分别为内存，磁盘（虚拟内存），正在从内存换出到磁盘和正在从磁盘换入内存；encoding；lru与server.lruclock相关；refcount为引用计数。

```
#define REDIS_VM_MEMORY 0       /* The object is on memory */
#define REDIS_VM_SWAPPED 1      /* The object is on disk */
#define REDIS_VM_SWAPPING 2     /* Redis is swapping this object on disk */
#define REDIS_VM_LOADING 3      /* Redis is loading this object from disk */
```

与此同时，Redis定义结构体vmPointer，表示被从内存换出到磁盘上的数据项。

```
/* The VM pointer structure - identifies an object in the swap file.
 *
 * This object is stored in place of the value
 * object in the main key->value hash table representing a database.
 * Note that the first fields (type, storage) are the same as the redisObject
 * structure so that vmPointer strucuters can be accessed even when casted
 * as redisObject structures.
 *
 * This is useful as we don't know if a value object is or not on disk, but we
 * are always able to read obj->storage to check this. For vmPointer
 * structures "type" is set to REDIS_VMPOINTER (even if without this field
 * is still possible to check the kind of object from the value of 'storage').*/
typedef struct vmPointer {
    unsigned type:4;
    unsigned storage:2; /* REDIS_VM_SWAPPED or REDIS_VM_LOADING */
    unsigned notused:26;
    unsigned int vtype; /* type of the object stored in the swap file */
    off_t page;         /* the page at witch the object is stored on disk */
    off_t usedpages;    /* number of pages used on disk */
} vmpointer;
```

这个设计非常巧妙，vmpointer的前32个字节与redisObject是可以互相转换的。vmPointer的具体定义待后文再行分析。

```
    off_t vm_page_size;
    off_t vm_pages;
    off_t vm_next_page; /* Next probably empty page */
    off_t vm_near_pages; /* Number of pages allocated sequentially */
    unsigned char *vm_bitmap; /* Bitmap of free/used pages */
```

Redis将内存按页(Page)管理，页的大小与数目在服务启动时指定。Redis通过位图索引server.vm_bitmap管理页，其中0表示未用，1表示已用。Redis中，一个页最多只存放一条数据，而一条数据可以拆分存放在多个页中。

```
    /* An I/O thread process an element taken from the io_jobs queue and
     * put the result of the operation in the io_done list. While the
     * job is being processed, it's put on io_processing queue. */
    list *io_newjobs; /* List of VM I/O jobs yet to be processed */
    list *io_processing; /* List of VM I/O jobs being processed */
    list *io_processed; /* List of VM I/O jobs already processed */
```

Redis中，将VM相关的读写都用任务(job)来描述及执行，io_newjobs表示新增的job，processing和processed分别表示正在执行和完成的job。Job总共有3种：LOAD、PREPARE_SWAP和DO_SWAP，分别为从磁盘读入内存、计算换出数据需要交换的页及换出到磁盘。

```
/* VM threaded I/O request message */
#define REDIS_IOJOB_LOAD 0          /* Load from disk to memory */
#define REDIS_IOJOB_PREPARE_SWAP 1  /* Compute needed pages */
#define REDIS_IOJOB_DO_SWAP 2       /* Swap from memory to disk */
typedef struct iojob {
    int type;   /* Request type, REDIS_IOJOB_* */
    redisDb *db;/* Redis database */
    robj *key;  /* This I/O request is about swapping this key */
    robj *id;   /* Unique identifier of this job:
                   this is the object to swap for REDIS_IOREQ_*_SWAP, or the
                   vmpointer objct for REDIS_IOREQ_LOAD. */
    robj *val;  /* the value to swap for REDIS_IOREQ_*_SWAP, otherwise this
                 * field is populated by the I/O thread for REDIS_IOREQ_LOAD. */
    off_t page; /* Swap page where to read/write the object */
    off_t pages; /* Swap pages needed to save object. PREPARE_SWAP return val */
    int canceled; /* True if this command was canceled by blocking side of VM */
    pthread_t thread; /* ID of the thread processing this entry */
} iojob;
```

job的结构体种，记录了相关的信息。任何Job，都通过queueIOJob()加入server.io_newjobs，当Redis发现能启动新的VM线程，或者有空闲的VM线程时，会执行job，线程的入口为IOThreadEntryPoint，该函数负责执行job，并将job从server.io_newjobs移入server.io_processing。然后Redis通过管道在线程间交流，VM线程将完成job的信号通过管道发送到主线程，主线程进行善后。Job具体的执行过程，在后文的数据读取过程中有更详细的分析。

4.1. 数据读取过程

对于getCommand()，从Redis中查询数据，Redis先用lookupKey()从哈希表中查找对应的dictEntity，校验其合法性后，如果服务器没有后台备份进程在工作，就更新它的时间戳。但如果启动了虚拟内存功能，就必须判断dictEntity的存储状态。如果该dictEntity正在内存中(REDIS_VM_MEMORY)，则不做操作；如果它正在被换出到磁盘

(REDIS_VM_SWAPPING)，则停止换出操作；如果它在磁盘，则调用vmLoadObject()将dictEntity从磁盘读出；如果它正在从磁盘换入到内存，则先调用vmLoadObject()将它立即从磁盘读出。具体来看这个过程，在命令处理的入口processCommand()中，

```
if (server.vm_enabled && server.vm_max_threads > 0 &&
    blockClientOnSwappedKeys(c,cmd)) return REDIS_ERR;
call(c,cmd);
```

在虚拟内存开启，并以多线程模式执行时，会调用blockClienkOnSwappedKeys()，将可能已经换出到磁盘的数据加载到内存，并在加载未完成前阻塞客户端连接（将客户端状态置为REDIS_IO_WAIT）。在blockClienkOnSwappedKeys()中，如果命令设置了预加载函数(vm_preload_proc)，则调用预加载函数处理，否则调用waitForMultipleSwappedKeys()，将需要的key载入内存。

```
int blockClientOnSwappedKeys(redisClient *c, struct redisCommand *cmd) {
    if (cmd->vm_preload_proc != NULL) {
        cmd->vm_preload_proc(c,cmd,c->argc,c->argv);
    } else {
        waitForMultipleSwappedKeys(c,cmd,c->argc,c->argv);
    }

    /* If the client was blocked for at least one key, mark it as blocked. */
    if (listLength(c->io_keys)) {
        c->flags |= REDIS_IO_WAIT;
        aeDeleteFileEvent(server.el,c->fd,AE_READABLE);
        server.vm_blocked_clients++;
        return 1;
    } else {
        return 0;
    }
}
```

waitForMultipleSwappedKeys和命令设置的预加载函数的载入过程均由waitForSwappedKey()开始，该函数首先从数据库中找到cmd需要的数据项的dictEntity对象，根据它存储的位置，如果为REDIS_VM_MEMORY，则直接返回，无需阻塞客户端；如果为REDIS_VM_SWAPPING，则用vmCancelThreadedIOJob(o)取消正在进行的换出操作，并直接返回，无需阻塞客户端。其余情况，均阻塞客户端。

每个客户端的结构体均有链表c->io_keys，保存所有等待swapping的对象的key。如果cmd需要的数据项在磁盘上，则将它的key加入c->io_keys。然后将{c, key}加入c->db->io_keys，这个db其实是全局的server->db，它为每个key，保存了一个阻塞在它上面的客户端的队列。

接下来，如果该key已经换出到磁盘，并且没有job将它从磁盘读出，则创建一个job，将它从磁盘换出，job中用vmpoiner对象标记需要换出的dictEntity。

```
int waitForSwappedKey(redisClient *c, robj *key) {
    struct dictEntry *de;
    robj *o;
    list *l;

    /* If the key does not exist or is already in RAM we don't need to
     * block the client at all. */
    de = dictFind(c->db->dict,key->ptr);
    if (de == NULL) return 0;
    o = dictGetEntryVal(de);
    if (o->storage == REDIS_VM_MEMORY) {
```

```
        return 0;
    } else if (o->storage == REDIS_VM_SWAPPING) {
        /* We were swapping the key, undo it! */
        vmCancelThreadedIOJob(o);
        return 0;
    }

    /* OK: the key is either swapped, or being loaded just now. */

    /* Add the key to the list of keys this client is waiting for.
     * This maps clients to keys they are waiting for. */
    listAddNodeTail(c->io_keys,key);
    incrRefCount(key);

    /* Add the client to the swapped keys => clients waiting map. */
    de = dictFind(c->db->io_keys,key);
    if (de == NULL) {
        int retval;

        /* For every key we take a list of clients blocked for it */
        l = listCreate();
        retval = dictAdd(c->db->io_keys,key,l);
        incrRefCount(key);
        redisAssert(retval == DICT_OK);
    } else {
        l = dictGetEntryVal(de);
    }
    listAddNodeTail(l,c);

    /* Are we already loading the key from disk? If not create a job */
    if (o->storage == REDIS_VM_SWAPPED) {
        iojob *j;
        vmpointer *vp = (vmpointer*)o;

        o->storage = REDIS_VM_LOADING;
        j = zmalloc(sizeof(*j));
        j->type = REDIS_IOJOB_LOAD;
        j->db = c->db;
        j->id = (robj*)vp;
        j->key = key;
        incrRefCount(key);
        j->page = vp->page;
        j->val = NULL;
        j->canceled = 0;
        j->thread = (pthread_t) -1;
        lockThreadedIO();
        queueIOJob(j);
        unlockThreadedIO();
    }
    return 1;
}
```

由于vm可能有多线程操作，所以需要将job队列操作放入临界区。queueIOJob的过程非常简单，将job加入server->io_newjobs队列，若当前的IO线程数少于上限，则创建一个IO线程处理该Job。

```
void queueIOJob(iojob *j) {
    redisLog(REDIS_DEBUG,"Queued IO Job %p type %d about key '%s'\n",
        (void*)j, j->type, (char*)j->key->ptr);
    listAddNodeTail(server.io_newjobs,j);
```

```
    if (server.io_active_threads < server.vm_max_threads)
        spawnIOThread();
}
```

IO线程的入口为IOThreadEntryPoint()，该函数循环处理server->io_newjobs中的job，正在被处理的任务，从server->io_newjobs中移入server->processing，根据job类型选择不同的处理方法，如REDIS_IOJOB_LOAD的job，由vmReadObjectFromSwap()处理，将磁盘的数据读入内存。完成的job被移入server->processed。最后，通过server->io_ready_pipe_write通知其它线程，处理server->processed中的job，每当完成一个job时，向io_ready_pipe写入一个字符。

server->io_ready_pipe_read和server->io_ready_pipe_write向线程间提供通信服务，在虚拟内存初始化过程vmInit()中，监听io_ready_pipe_read上的读事件，事件响应函数vmThreadedIOCompletedJob处理完成的job。

vmThreadedIOCompletedJob根据job的类型处理其“善后”工作，例如REDIS_IOJOB_LOAD，此时key已被从vm中换入内存，调用handleClientsBlockedOnSwappedKey唤醒被该key阻塞的客户端。如前文所述，c->db->io_keys（即server->db->io_keys)中保存了{key, c}，即阻塞在该key上的所有客户端。对于db->io_keys中的所有c，调用dontWaitForSwappedKey()将他们从db->io_keys中删除；同时，c->io_keys里保存了该客户端需要阻塞读取的key，也将被换出的key从c->io_keys中删除。最后，若c已经不再被任何key阻塞，将它加入server.io_ready_clients，准备进行“正常”的读写操作。

最后一个问题，阻塞状态的客户端，加入server.io_ready_clients回到正常状态后，在哪里重新监听READABLE事件？前文分析Redis的事件机制时，曾提到aeMain()在每次epoll循环前，会执行beforeSleep()方法，Redis在该方法中检查server.io_ready_clients，若有ready的客户端，则重新在它上面监听READABLE事件，并处理它的命令。

4.2. 数据交换策略

Redis的虚拟内存系统有两种可用的换入换出策略：阻塞式(Blocking Virtual Memory)和多线程非阻塞式(Threaded Virtual Memory IO)，相关代码都在vm.c中。

Redis在第一次建库时（无论是AOF备份还是Snapshot备份），如果需要将数据换出到vm，均使用阻塞式交换；之后Redis会在serverCron()中与vm交换数据。

```
    /* Swap a few keys on disk if we are over the memory limit and VM
     * is enbled. Try to free objects from the free list first. */
    if (vmCanSwapOut()) {
        while (server.vm_enabled && zmalloc_used_memory() >
                server.vm_max_memory)
        {
            int retval = (server.vm_max_threads == 0) ?
                        vmSwapOneObjectBlocking() :
                        vmSwapOneObjectThreaded();
            // ...
            if (retval == REDIS_ERR || server.vm_max_threads > 0) break;
        }
    }
```

vmSwapOneObjectBlocking()是阻塞式交换，vmSwapOneObjectThreaded()是多线程交换，最终交换的代码都在vmSwapOneObject()中。Redis每次从每个库中随机选择5个数据，用computeObjectSwappability()测试它们换出到磁盘的可行性，最后选择1个最需要换出到磁盘的，用阻塞或非阻塞的方式将它换出到磁盘。

多线程模式下，换出的方式和读入类似，也是创建一个类型为REDIS_IOJOB_PREPARE_SWAP的job，启动该线程后，按Snapshot备份的编码方式，将需要换出的数据编码，计算其长度，进而得到需要换出的页的数目。然后寻找一块连续的满足要换出的页的数目的区域，创建类型为REDIS_IOJOB_DO_SWAP的job，进行换出，并标记该数据的状态。Redis在vm中寻找连续空闲区域的算法比较简单，直接进行简单的枚举：如果当前区域空闲，则判断是否有满足需求连续的空闲区域；如果当前区域有数据，则标记遇到有数据的区域的次数，如果连续REDIS_VM_MAX_RANDOM_JUMP/4次遇到非空闲区域，则将指针往前跳跃一个不超过REDIS_VM_MAX_RANDOM_JUMP的随机数。

阻塞式换出就比较简单了，只是将多线程模式下的几个步骤阻塞式执行。

5. 备份机制

Redis是内存数据库，支持两种方式——snapshot和aof，将数据从内存dump到磁盘。snapshot是快照式备份，每次将Redis全库dump到磁盘，aof是流水式备份，每次将Redis数据库的修改日志dump到磁盘，并定期整理日志。

5.1. Snapshot

Redis支持Snapshot（快照）式备份。Redis可以自动检测备份时机，设置每N秒检查，若发生M次以上数据更新操作，则开始Snapshot备份，也可以由客户端发送save或bgsave命令手动启动备份。

save是阻塞式备份，备份过程中Redis会停止服务；bgsave是后台备份，Redis将新建一个备份进程负责将全库dump到磁盘。

saveCommand()中，首先检查是否有bgsave的后台备份进程，若没有，则执行rdbSave()进行全库备份。

bgsaveCommand()中，也会检查是否有bgsave的后台备份进程，若没有，则执行rdbSaveBackground()，启动备份子进程，在后台全库备份。备份子进程最终也是通过rdbSave()备份数据库。

rdbSaveBackground()中，首先通过前文所说的waitEmptyIOJobsQueue()检查是否有vm的IO线程在进行数据交换，如果有则阻塞，等待所有vm的IO线程完成工作。然后fork()备份子进程。在父进程中，server.bgsavechildpid记录了备份子进程的pid，并通过updateDictResizePolicy()禁止Hash表自动扩容。在子进程中，如果启用了vm，则打开vm swap文件，然后调用rdbSave()执行备份。因为之前已经检查了所有vm的IO线程是否完成，因此这里打开vm的swap文件并不会和vm的IO线程冲突。

```
int rdbSaveBackground(char *filename) {
    pid_t childpid;

    if (server.bgsavechildpid != -1) return REDIS_ERR;
    if (server.vm_enabled) waitEmptyIOJobsQueue();
    server.dirty_before_bgsave = server.dirty;
```

```
    if ((childpid = fork()) == 0) {
        /* Child */
        if (server.vm_enabled) vmReopenSwapFile();
        if (server.ipfd > 0) close(server.ipfd);
        if (server.sofd > 0) close(server.sofd);
        if (rdbSave(filename) == REDIS_OK) {
            _exit(0);
        } else {
            _exit(1);
        }
    } else {
        /* Parent */
        if (childpid == -1) {
            redisLog(REDIS_WARNING,"Can't save in background: fork: %s",
                strerror(errno));
            return REDIS_ERR;
        }
        redisLog(REDIS_NOTICE,"Background saving started by pid %d",childpid);
        server.bgsavechildpid = childpid;
        updateDictResizePolicy();
        return REDIS_OK;
    }
    return REDIS_OK; /* unreached */
}
```

rdbSave()中首先通过waitEmptyIOJobsQueue()检查vm的IO线程，并阻塞直到所有vm的IO线程完成。因为备份过程中，需要备份vm的swap文件，如果有未完成的vm的IO线程，会导致数据不同步。

首先建立一个tmp文件，向它写入备份数据。依次循环每个db：server.db, server.db+1, ..., server.db+server.dbnum，通过dict的迭代器dictIterator访问db中的所有数据，依次写入tmp文件。

Redis在写备份文件时做了许多优化，例如rdbSaveLen()用于写入长度信息，写入的数字不超过32bit整数。Redis将长度数字按二进制长度分三类：小于6bit，6bit至14bit，14bit至32bit，并用前缀REDIS_RDB_6BITLEN(00)、REDIS_RDB_14BITLEN(01)、REDIS_RDB_32BITLEN(10)标示数字长度。将前缀与数字一起写入磁盘。这个优化类似于Protobuf里压缩数字的方法。类似的压缩还有很多，再此不一一分析。

```
int rdbSaveLen(FILE *fp, uint32_t len) {
    unsigned char buf[2];
    int nwritten;

    if (len < (1<<6)) {
        /* Save a 6 bit len */
        buf[0] = (len&0xFF)|(REDIS_RDB_6BITLEN<<6);
        if (rdbWriteRaw(fp,buf,1) == -1) return -1;
        nwritten = 1;
    } else if (len < (1<<14)) {
        /* Save a 14 bit len */
        buf[0] = ((len>>8)&0xFF)|(REDIS_RDB_14BITLEN<<6);
        buf[1] = len&0xFF;
        if (rdbWriteRaw(fp,buf,2) == -1) return -1;
        nwritten = 2;
    } else {
        /* Save a 32 bit len */
        buf[0] = (REDIS_RDB_32BITLEN<<6);
```

```
        if (rdbWriteRaw(fp,buf,1) == -1) return -1;
        len = htonl(len);
        if (rdbWriteRaw(fp,&len,4) == -1) return -1;
        nwritten = 1+4;
    }
    return nwritten;
}
```

在备份文件中，Redis写入type/key/value数据，并放弃所有过期的数据。特别地，对于vm中的数据，会先读入内存，再将数据写入备份文件。

父进程在serverCron中检查备份进程，如果存在bgsave进程或者bgrewrite进程（AOF备份，下节分析），则wait3()等待进程完成，完成后调用backgroundSaveDoneHandler()或者backgroundRewriteDoneHandler()处理。

snapshot式备份中，Redis会停止vm的换入换出操作，停止更新LRU策略中的标记信息，但不会影响Redis对内存中的数据的读写。Redis通过调整snapshot备份的粒度，适应各种应用需求。

5.2. AOF

除了Snapshot备份模式外Redis还支持AOF(流水式)备份，它保存所有操作的commit log，并能自动地进行全库备份和删除无用的commit log。

Redis在写commit log时，Redis并不是每次处理请求时都将请求写入磁盘，它会用一段内存Buffer缓存commit log，并在一定时间将缓存中的内容统一写入磁盘。 为了避免磁盘缓存的影响，可以设置三种策略进行fsync()：每次写操作后均调用fsync()，每秒调用一次fsync()，从不调用fsync()，三种不同的策略获得不同的性能和一致性。

Redis将所有操作保存在commit log中，commit log的文件是追加写。当commit log的大小无法承受时，可以手工通过bgrewriteaof命令产生一个快照（这个不同于Snapshot备份），具体构造方式后文分析。

AOF有四种操作:

- feedAppendOnlyFile() – 将命令写入AOF。该方法在call()中被调用，用于将所有Redis处理的命令写入AOF；该方法在Redis发现过期的Keys被调用，记录清除过期Key的操作

call()是Redis中所有命令处理的入口，当启用了AOF且数据有变化时(server.dirty有变化），将命令用feedAppendOnlyFile()写入AOF，该函数中，将命令编码后写入server.aofbuf，当后台rewriteaof进程存在时，同时将编码后的命令写入server.bgrewritebuf，bgrewritebuf的作用后文解释。

```
    /* Append to the AOF buffer. This will be flushed on disk just before
     * of re-entering the event loop, so before the client will get a
     * positive reply about the operation performed. */
    server.aofbuf = sdscatlen(server.aofbuf,buf,sdslen(buf));

    /* If a background append only file rewriting is in progress we want to
     * accumulate the differences between the child DB and the current one
     * in a buffer, so that when the child process will do its work we
     * can append the differences to the new append only file. */
    if (server.bgrewritechildpid != -1)
        server.bgrewritebuf = sdscatlen(server.bgrewritebuf,buf,sdslen(buf));
```

- rewriteAppendOnlyFile() – 产生快照，并更新aof文件。

rewriteAppendOnlyFile()只在 rewriteAppendOnlyFileBackground()中被调用。Redis产生AOF快照主要分为以下几步：

(1) fork()一个rewrite子进程，调用rewriteAppendOnlyFile()产生快照。

(2) 当rewrite进程开始后，rewriteAppendOnlyFile()扫描数据库中所有数据，将他们编码后写入临时文件。AOF文件的编码形式为文本，即人肉可读的编码。

(3)rewrite时父进程照常接收请求，并将流水日志写入server.bgrewriteaofbuf中。

(4)子进程完成工作，父进程在serverCron()中通过wait3()获知其状态后，调用backgroundRewriteDoneHandler()将server.bgrewriteaofbuf中的内容作为新的commit log，覆盖原有server.aofbuf。

(5) 父进程将rewrite子进程生成的临时文件改名，作为新的aof文件。用于未来恢复数据。

Redis的AOF快照机制的基础，是数据库的大小一定小于操作日志的大小，否则产生的快照文件可能远远超过commit log文件的大小。因此，此处有一点值得考虑，rewrite过程是否可以只写入aofbuf中改变了的数据的快照?

- flushAppendOnlyFile() – 将内存buffer中的commit log写到磁盘上。Redis在beforeSleep()中，及关闭AOF功能时，将内存buffer中的log写入磁盘。
- loadAppendOnlyFile() – 重放AOF文件。该方法在Redis启动时被调用，从AOF文件中重建数据库。

Redis通过AOF重建时，构造一个虚拟的client()，向自己发送重建的命令。而恢复数据只需要将AOF快照重新载入数据库，并回放commit log中的操作。

6. 主从同步

Redis支持主从同步，其官方文档 http://www.redis.io/topics/replication 简要介绍了它的主从同步机制。翻译官方文档的文章，Redis的主从同步有以下特点：

- 一个Master可以有多个Slave
- Slave可以接受其它Slave的连接，因此Masters和Slaves之间可以行程一个网络
- 同步时，作为Master的一端（可能其状态是Slave）的同步是非阻塞的，它可以继续处理命令；作为Slave一端的第一次同步是阻塞的。
- 主从机制可以用于提高扩展性，比如可以用多个Slaves处理复杂的读请求。
- 可以通过Slave备份数据，以降低Master的负载。

6.1. 建立连接

接下来我们看Redis中Slave和Master是如何建立连接的。Redis通过server.replstate表明Master和Slave的状态，初始时，状态均为

REDIS_REPL_NONE。server.masterhost和server.masterport为Master的地址，Master结点的这两个变量为NULL。

Slave的server.replstate状态除了REDIS_REPL_NONE外，还有

```
/* Slave replication state - slave side */
#define REDIS_REPL_NONE 0   /* No active replication */
#define REDIS_REPL_CONNECT 1    /* Must connect to master */
#define REDIS_REPL_TRANSFER 2    /* Receiving .rdb from master */
#define REDIS_REPL_CONNECTED 3  /* Connected to master */
```

Master对于每个Slave都维护一个状态，在结构体redisClient.replstate中，因为Slave对于Master，其本质也是一个客户端。Master对每个Slave标记状态，有四种:

```
/* Slave replication state - from the point of view of master
 * Note that in SEND_BULK and ONLINE state the slave receives new updates
 * in its output queue. In the WAIT_BGSAVE state instead the server is waiting
 * to start the next background saving in order to send updates to it. */
#define REDIS_REPL_WAIT_BGSAVE_START 3 /* master waits bgsave to start feeding
it */
#define REDIS_REPL_WAIT_BGSAVE_END 4 /* master waits bgsave to start bulk DB
transmission */
#define REDIS_REPL_SEND_BULK 5 /* master is sending the bulk DB */
#define REDIS_REPL_ONLINE 6 /* bulk DB already transmitted, receive updates */
```

REDIS_REPL_WAIT_BGSAVE_START表示Master准备dump数据到磁盘，任何新建的Slave连接均处于该状态；Master开始数据dump后，将Slave的状态修改为REDIS_REPL_WAIT_BGSAVE_END，当dump完成后，通知Slave，状态变为REDIS_REPL_SEND_BULK，准备向其发送数据；当发送完成，Slave就绪后，状态变为REDIS_REPL_ONLINE，至此Master可以向状态为REDIS_REPL_ONLINE的Slave发送更新命令。

对于Slave，如果server.replstate!=REDIS_REPL_CONNECTED，则无法处理命令（获取Slave状态的命令除外）；对于Master，如果c.replstate!=REDIS_REPL_ONLINE，也不会向它发送命令。

serverCron()中每隔10秒会调用replicationCron()，处理主从同步相关的功能。replicationCron()会检测同步数据传输超时，Slave与Master连接断开等问题。在分析可能的故障前，先分析建立连接的过程。

6.1.1. Master

Redis启动时可以通过配置文件指定为Master状态或Slave状态，Slave也可以通过Sync命令与另一个Master（可能是Master，也可能是与Master有连接的Slave）建立主从连接。下面分析syncCommand()的处理。

首先，如果发送sync命令的结点已经是Slave状态，则无需再次同步。如果接受sync指令的结点，本身也是Slave，且没有与任何Master建立连接，则无法响应sync命令。如果Slave与Master之间还有其它交互命令没有处理完，也无法继续响应sync命令。

然后Master开始检测bgsave状态，如果已经有bgsave进程，再判断是否正在响应其它Slave的sync命令，且正在dump数据（Slave的replstate为REDIS_REPL_BGSAVE_END），则直接将新Slave的replstate状态置为REDIS_REPL_BGSAVE_END，并准备将dump好的数据传给新Slave。如果没有dump好的

数据，则将新Slave的状态置为REDIS_REPL_BGSAVE_START，并等待bgsave进程完成，之后再启动bgsave，为Slave dump数据。

如果没有bgsave进程，则启动新的bgsave进程，并将Slave的状态置为REDIS_REPL_BGSAVE_END。

最后，将新Slave加入Master的server.slaves列表。

```
void syncCommand(redisClient *c) {
    /* ignore SYNC if aleady slave or in monitor mode */
    if (c->flags & REDIS_SLAVE) return;

    /* Refuse SYNC requests if we are a slave but the link with our master
     * is not ok... */
    if (server.masterhost && server.replstate != REDIS_REPL_CONNECTED) {
        addReplyError(c,"Can't SYNC while not connected with my master");
        return;
    }

    /* SYNC can't be issued when the server has pending data to send to
     * the client about already issued commands. We need a fresh reply
     * buffer registering the differences between the BGSAVE and the current
     * dataset, so that we can copy to other slaves if needed. */
    if (listLength(c->reply) != 0) {
        addReplyError(c,"SYNC is invalid with pending input");
        return;
    }

    redisLog(REDIS_NOTICE,"Slave ask for synchronization");
    /* Here we need to check if there is a background saving operation
     * in progress, or if it is required to start one */
    if (server.bgsavechildpid != -1) {
        /* Ok a background save is in progress. Let's check if it is a good
         * one for replication, i.e. if there is another slave that is
         * registering differences since the server forked to save */
        redisClient *slave;
        listNode *ln;
        listIter li;

        listRewind(server.slaves,&li);
        while((ln = listNext(&li))) {
            slave = ln->value;
            if (slave->replstate == REDIS_REPL_WAIT_BGSAVE_END) break;
        }
        if (ln) {
            /* Perfect, the server is already registering differences for
             * another slave. Set the right state, and copy the buffer. */
            listRelease(c->reply);
            c->reply = listDup(slave->reply);
            c->replstate = REDIS_REPL_WAIT_BGSAVE_END;
            redisLog(REDIS_NOTICE,"Waiting for end of BGSAVE for SYNC");
        } else {
            /* No way, we need to wait for the next BGSAVE in order to
             * register differences */
            c->replstate = REDIS_REPL_WAIT_BGSAVE_START;
            redisLog(REDIS_NOTICE,"Waiting for next BGSAVE for SYNC");
        }
    } else {
        /* Ok we don't have a BGSAVE in progress, let's start one */
        redisLog(REDIS_NOTICE,"Starting BGSAVE for SYNC");
```

```
        if (rdbSaveBackground(server.dbfilename) != REDIS_OK) {
            redisLog(REDIS_NOTICE,"Replication failed, can't BGSAVE");
            addReplyError(c,"Unable to perform background save");
            return;
        }
        c->replstate = REDIS_REPL_WAIT_BGSAVE_END;
    }
    c->repldbfd = -1;
    c->flags |= REDIS_SLAVE;
    c->slaveseldb = 0;
    listAddNodeTail(server.slaves,c);
    return;
}
```

如前文Snapshot快照分析，当bgsave进程备份完成时，在serverCron()中会调用backgroundSaveDoneHandler()处理，该函数中调用updateSlavesWaitingBgsave()处理等待bgsave的Slave结点。

updateSlavesWaitingBgsave()检查server.slaves列表，当发现状态为REDIS_REPL_WAIT_BGSAVE_START的结点时，会再次启动bgsave进程进行dump数据。当发现状态为REDIS_REPL_WAIT_BGSAVE_START的结点时，会准备将数据发送给Slave，并将Slave的状态修改为REDIS_REPL_SEND_BULK。Master在Slave上监听WRITEABLE事件，当Slave可写时，调用sendBulkToSlave()将数据发送到Slave。

在Master中，sendBulkToSlave()将数据从磁盘读入，通过socket发送到Slave，完成后删除WRITEABLE事件，并将Slave状态改为REDIS_REPL_ONLINE。然后再次监听Slave的WRITEABLE事件，当Slave可写时，表明Slave已经准备好开始同步指令。

6.1.2. Slave

Redis可以在配置文件中指定为Slave模式，并指定Master的地址，这样的Slave结点启动时即为REDIS_REPL_ONLINE状态，然后在replicationCron()中调用syncWithMaster()与Master同步。

syncWithMaster()中，向Master发送sync命令，并准备接收数据的目录。然后通过readSyncBulkPayload()处理Master发送的dump的数据。Slave通过syncRead()和syncWrite()与Master传输数据，这两个方法底层是异步IO的，但封装成阻塞型，因此Slave第一次同步是阻塞的。

replicationCron()会定时Master的dump数据是否发送完成，如果长时间没有收到dump数据的数据包，Slave会通过replicationAbortSyncTransfer()取消数据同步。

6.2. 指令同步

在call()中，Master会将改变了数据的命令通过replicationFeedSlaves()同步到Slaves中。Slave以处理普通命令的流程处理这些Master发来的命令。

特别地在serverCron()中，Master会删除过期的数据，Slave则等待Master同步DEL指令将过期数据删除。

replicationCron()中，Master会定时向所有Slave发送心跳指令，同时，Slave的replicationCron()会通过Ping指令检查Slave与Master的连接状态，如果Slave长时间没有收到主机的Ping，则会断开与主机的连接。

6.3. 主从转换

slaveof可以转换Redis中结点的状态。对于Slave结点，slaveof no one可以将Slave与Master断开，并将Slave转为主机。对于Master，slaveof ip port可以讲主机转为Slave。

Redis的主从转换非常简单，如果同步未完成，则取消同步；否则，直接改变server.masterhost等状态。

参考文献

[1] Redis, *http://redis.io*

[2] Binary-safe, *http://en.wikipedia.org/wiki/Binary_safe*

[3] malloc_size(), Mac OS X Manual Page, *http://developer.apple.com/library/mac/#documentation/Darwin/Reference/ManPages/man3/malloc_size.3.html*

[4] BeansDB, *http://code.google.com/p/beansdb/*

[5] Redis进阶教程-aof(append only file)日志文件, *http://lgone.com/html/y2010/757.html*

[6] Redis源代码分析, *http://www.petermao.com/category/redis*