〈조 병 욱〉

JVM GC와 메모리 Tuning

1. GC란 무엇인가?

GC는 Garbage Collection의 약자로 Java 언어의 중요한 특징중의 하나이다.

GC는 Java Application에서 사용하지 않는 메모리를 자동으로 수거하는 기능을 말한다.

예전의 전통적인 언어인 C에서는 malloc, free 등을 이용해서 메모리를 할당하고, 일일이 그 메모리를 수거해줘야 했다. 그러나 Java 언어에서는 GC 기술을 사용함에 따라, 개발자는 메모리 관리로부터 좀더 자유롭게 되었다.

2. GC의 동작 방법은 어떻게 되는가?

1) JVM 메모리 영역

GC의 동작 방법을 이해하기 위해서는 Java의 메모리 구조를 먼저 이해할 필요가 있다.

일반적으로 Application에서 사용되는 객체는 오래 유지 되는 객체보다, 생성되고 얼마안있어서 사용되지 않는 경우가 많다. 〈그림 1 참조〉

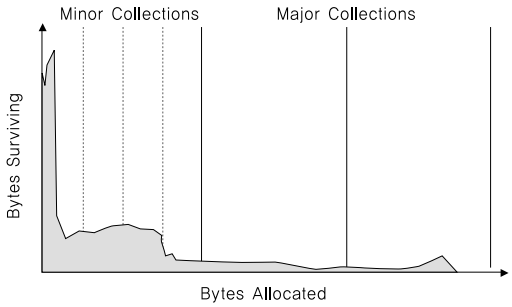

〈그림 1. 메모리 foot print〉

그래서 Java에서는 크게 두가지 영역으로 메모리를 나누는데 Young 영역과 Old 영역이 그것이다.

Young 영역은 생긴지 얼마 안된 객체들을 저장하는 장소이고, Old 영역은 생성된지 오래된 객체를 저장하는 장소이다. 각 영역의 성격이 다른 만큼 GC의 방법도 다르다.

먼저 Java의 메모리 구조를 살펴보자.

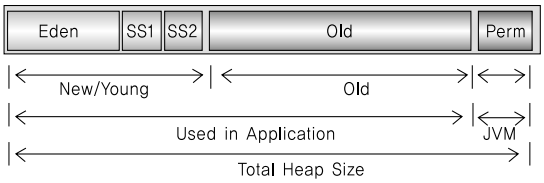

〈그림 2. Java 메모리 구조〉

Java의 메모리 영역은 앞에서 이야기한 두 영역 (Young 영역, Old 영역)과 Perm 영역 이렇게 3가지로 영역으로 구성된다.

〈표 1. Java 메모리 영역〉

영역	설명
New/Young	이 영역은 Java 객체가 생성되자마자 저장되고, 생긴지 얼마 안되는 객체가 저장되는 곳이다. Java 객체가 생성되면 이 영역에서 저장되다가, 시간이 지남에 따라 우선순위가 낮아지면 Old 영역으로 옮겨진다.
Old 영역	New/Young 영역에서 저장되었던 객체중에 오래된 객체가 이동되어서 저장되는 영역
Perm 영역	Class,Method 등의 Code 등이 저장되는 영역으로 JVM에 의해서 사용된다.

2) GC 알고리즘

그러면 이 메모리 영역을 JVM이 어떻게 관리하는지에 대해서 알아보자.

JVM은 New/Young 영역과, Old 영역 이 두영역에 대해서만 GC를 수행한다. Perm 영역은 앞에서 설명했듯이 Code가 저장되는 영역이기 때문에, GC가 일어날 필요가 없다. Perm 영역은 Code가 모두 Load되고 나면 거의 일정한 수치를 유지한다.

O Minor GC

먼저 New/Young 영역의 GC방법을 살펴보자. New/Young 영역의 GC를 Minor GC라고 부르는데, New/Young 영역은 Eden과 Survivor라는 두 가지 영역으로 또 나뉘어 진다. Eden 영역은 Java 객체가 생성되자 마자 저장 되는곳이다. 이렇게 생성된 객체는 Minor GC가 발생할 때 Survivor 영역으로 이동된다.

Survivor 영역은 Survivor 1과 Suvivor 2 영역 두 영역으로 나뉘어 지는데, Minor GC가 발생하면 Eden과 Survivor 1에 Alive되어 있는 객체를 Suvivor 2로 복사한다. 그리고 Alive되어 있지 않는 객체는 자연히 Suvivor 1에 남아있게 되고, Survivor 1과 Eden 영역을 Clear한다. (결과적으로 Alive된 객체만 Survivor 2로 이동한 것이다.)

다음번 Minor GC가 발생하면 같은 원리로 Eden과 Survivor 2 영역에서 Alive되어 있는 객체를 Survivor 1에 복사한다. 계속 이런 방법을 반복적으로 수행하면서 Minor GC를 수행한다.

이렇게 Minor GC를 수행하다가, Survivor 영역에서 오래된 객체는 Old 영역으로 옮기게 된다.

이런 방식의 GC 알고리즘을 Copy & Scavenge라고 한다. 이 방법은 매우 속도가 빠르며 작은 크기의 메모리를 Collecting하는데 매우 효과적이다. Minor GC의 경우에는 자주 일어나기 때문에, GC에 소요되는 시간이 짧은 알고리즘이 적합하다.

이 내용을 그림을 보면서 살펴보도록 하자.

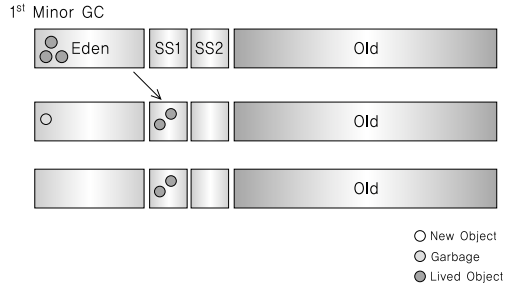

〈그림 3-1. 1st Minor GC〉

Eden에서 Alive된 객체를 Suvivor1으로 이동한다. Eden 영역을 Clear한다.

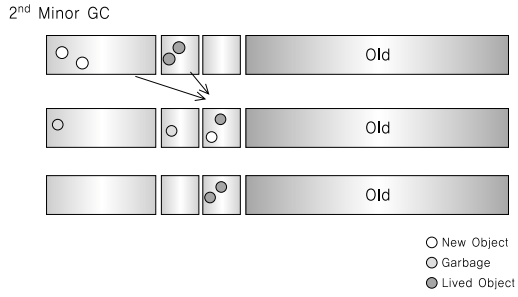

〈그림 3-2. 2nd Minor GC〉

Eden 영역에 Alive된 객체와 Suvivor 1 영역에 Alive된 객체를 Survivor 2에 copy한다

Eden 영역과 Suvivor 2 영역을 clear한다.

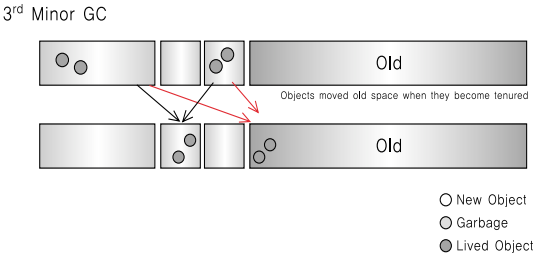

〈그림 3-3. 3rd Minor GC〉

객체가 생성된 시간이 오래지나면 Eden과 Suvivor 영역에 있는 오래된 객체들을 Old 영역으로 이동한다.

O Full GC

Old 영역의 Garbage Collection을 Full GC라고 부르며, Full GC에서는 Mark & Compact라는 알고리즘을 이용한다. Mark & Compact 알고리즘은 전체 객체들의 reference를 쭉 따라가면서 reference가 연결되지 않는 객체는 Mark한다. 이 작업이 끝나면 사용되지 않는 객체는 모두 Mark가 되고, 이 mark된 객체를 삭제한다.〈그림 4 참고〉 (실제로는 compact라고 해서, mark된 객체로 생기는 공간을 unmark된 즉 사용하는 객체로 메꾸어 버린다.)

Full GC는 매우 속도가 느리며, Full GC가 일어나는 도중에는 순간적으로 Java Application이 멈춰 버리기 때문에, Full GC가 일어나는 정도와 Full GC에 소요되는 시간은 Application의 성능과 안정성에 아주 큰 영향을 준다.

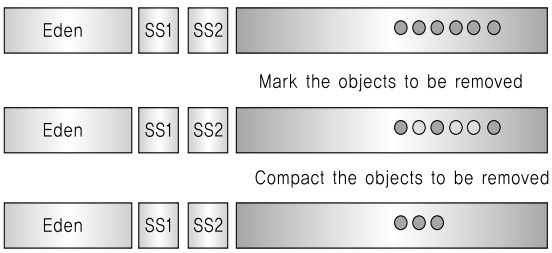

〈그림 4. Full GC〉

3. GC가 왜 중요한가?

Garbage Collection 중에서 Minor GC의 경우 보통 0.5초 이내에 끝나기 때문에 큰 문제가 되지 않는다. 그러나 Full GC의 경우 보통 수 초가 소요가 되고, Full GC동안에는 Java Application이 멈춰버리기 때문에 문제가 될 수 있다.

예를 들어 게임 서버와 같은 Real Time Server를 구현을 했을때, Full GC가 일어나서 5초 동안 시스템이 멈춘다고 생각해보자.

또 일반 WAS에서도 5~10초 동안 멈추면, 멈추는 동안 사용자의 Request가 Queue에 저장되었고, Full GC가 끝난 후에 그 요청이 한꺼번에 들어오게 되면 과부하에 의한 여러 장애를 만들 수 있다.

그래서 원활한 서비스를 위해서는 GC를 어떻게 일어나게 하느냐가 시스템의 안정성과 성능에 큰 변수로 작용할 수 있다.

4. 다양한 GC 알고리즘

앞에서 설명한 기본적인 GC방법 (Scavenge와 Mark and compact)이외에 JVM에서는 좀더 다양한 GC 방법을 제공하고 그 동작방법이나 사용방법도 틀리다. 이번에는 다양한 GC 알고리즘에 대해서 알아보자. 현재 (JDK 1.4)까지 나와 있는 JVM의 GC방법은 크게 아래 4가지를 지원하고 있다.

- Default Collector
- Parallel GC for young generation (from JDK 1.4)
- Concurrent GC for old generation (from JDK 1.4)
- Incremental GC (Train GC)

1) Default Collector

이 GC 방법은 앞에서 설명한 전통적인 GC방법으로 Minor GC에 Scavenge를, Full GC에 Mark & compact 알고리즘을 사용하는 방법이다. 이 알고리즘은 이미 앞에서 설명했기 때문에 별도의 설명은 생략한다.

JDK 1.4에서부터 새로 적용되는 GC방법은 Parallel GC와 Concurrent GC 두 가지 방법이 있다. Parallel GC는 Minor GC를 좀더 빨리 하게 하는 방법이고 (Throughput 위주) Concurrent GC는 Full GC시에 시스템의 멈춤(Pause)현상을 최소화하는 GC방법이다.

2) Parallel GC

JDK 1.3까지 GC는 하나의 Thread에서 이루어진다. Java가 Multi Thread환경을 지원함에도 불구하고, 1 CPU에서는 동시에 하나의 Thread만을 수행할 수 밖에 없기 때문에, 예전에는 하나의 CPU에서만 GC를 수행했지만, 근래에 들어서 하나의 CPU에서 동시에 여러 개의 Thread를 실행할 수 있는 Hyper Threading기술이나, 여러 개의 CPU를 동시에 장착한 HW의 보급으로 하나의 HW Box에서 동시에 여러 개의 Thread를 수행할 수 있게 되었다.

JDK 1.4부터 지원되는 Parallel GC는 Minor GC를 동시에 여러 개의 Thread를 이용해서 수행하는 방법으로 하나의 Thread를 이용하는 것보다 훨씬 빨리 작업할 수 있다.

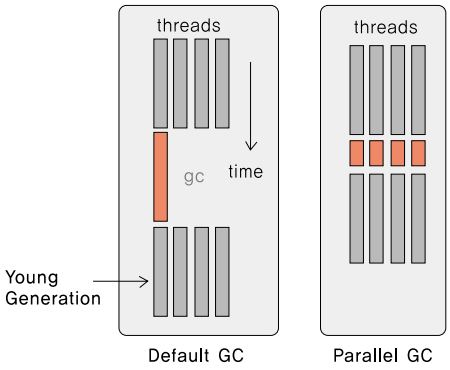

〈그림 5. Parallel GC 개념도〉

〈그림 5〉을 보자 왼쪽의 Default GC 방법은 GC가 일어날때 Thread들이 작업을 멈추고, GC를 수행하는 thread만 gc를 수행한다(그림에서 빨간영역), Parallel GC에서는 동시에 여러 thread들이 gc를 수행하기 때문에, gc에 소요되는 시간이 낮아진다.

Parallel GC가 언제나 유익한 것은 아니다. 앞에서도 말했듯이 1 CPU에서는 동시에 여러 개의 thread를 실행할 수 없기 때문에 오히려 Parallel GC가 Default GC에 비해서 느리다. 2 CPU에서도 Multi thread에 대한 지원이나 계산 등을 위해서 CPU Power가 사용되기 때문에, 최소한 4 CPU, 256M 정도의 메모리를 가지고 있는 HW에서 Parallel GC가 유용하게 사용된다.

Parallel GC는 크게 두 가지 종류의 옵션을 가지고 있는데, Low-pause 방식과 Throughput 방식의 GC방식이 있다.

Solaris 기준에서 Low-pause Parallel GC는 -

XX:+UseParNewGC 옵션을 사용한다. 이 모델은 Old 영역을 GC할 때 다음에 설명할 Concurrent GC 방법과 함께 사용할 수 있다. 이 방법은 GC가 일어날 때 빨리 GC하는 것이 아니라 GC가 발생할 때 Application이 멈춰지는 현상(pause)를 최소화하는데 역점을 뒀다.

Throughput 방식의 Parallel GC는 -XX:+UseParallelGC (Solaris 기준) 옵션을 이용하며 Old 영역을 GC할 때는 Default GC (Mark and compact)방법만을 사용하도록 되어 있다. Minor GC가 발생했을 때, 되도록이면 빨리 수행하도록 throughput에 역점을 두었다.

그 외에도 Parallel GC를 수행할 때 동시에 몇 개의 Thread를 이용하여 Minor영역을 Parallel GC할지를 결정할 수 있는데, -XX:ParallelGCThreads=〈desired number〉 옵션을 이용하여 Parallel GC에 사용되는 Thread의 수를 지정할 수 있다.

3) Concurrent GC

앞에서도 설명했듯이, Full GC 즉 Old 영역을 GC하는 경우에는 그 시간이 길고 Application이 순간적으로 멈춰버리기 때문에, 시스템 운용에 문제가 된다.

그래서 JDK 1.4부터 제공하는 Concurrent GC는 기존의 이런 Full GC의 단점을 보완하기 위해서 Full GC에 의해서 Application이 멈추어 지는 현상을 최소화 하기 위한 GC방법이다.
Full GC에 소요되는 작업을 Application을 멈추고 진행하는 것이 아니라, 일부는 Application이 돌아가는 단계에서 수행하고, 최소한의 작업만을 Application이 멈췄을 때 수행하는 방법으로 Application이 멈추는 시간을 최소화한다.

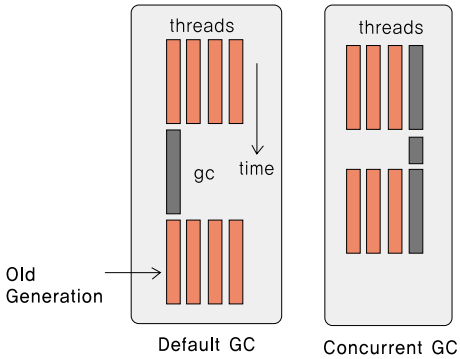

〈그림 6. Concurrent GC 개념도〉

〈그림 6〉에서와 같이 Application이 수행중일 때(붉은 라인) Full GC를 위한 작업을 수행한다(Sweep, mark). Application을 멈추고 수행하는 작업은 일부분 (initial-mark, remark 작업)만을 수행하기 때문에, 기존 Default GC의 Mark & Sweep Collector에 비해서 Application이 멈추는 시간이 현저하게 줄어든다.

Solaris JVM에서는 -XX:+UseConcMarkSweepGC Parameter를 이용해 세팅한다.

4) Incremental GC (Train GC)

Incremental GC 또는 Train GC라고도 불리는 GC방법은 JDK 1.3에서부터 지원된 GC방법이다. 앞에서 설명한 Concurrent GC와 비슷하게, 의도 자체는 Full GC에 의해서 Application이 멈추는 시간을 줄이고자 하는데 있다.

Incremental GC의 작동방법은 간단하다. Minor GC가 일어날 때마다 Old 영역을 조금씩 GC를 해서 Full GC가 발생하는 횟수나 시간을 줄이는 방법이다.

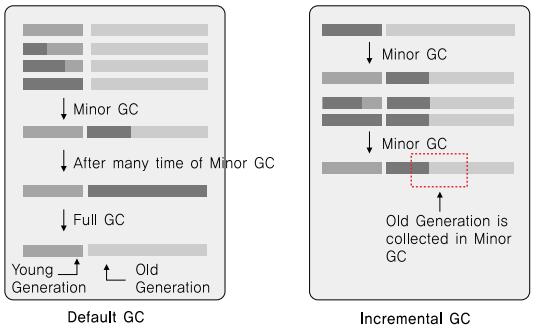

〈그림 7. Incremental GC 개념도〉

〈그림 7〉에서 보듯이 왼쪽의 Default GC는 Full GC가 일어난 후에나 Old 영역이 Clear된다. 그러나, 오른쪽의 Incremental GC를 보면 Minor GC가 일어난 후에, Old 영역이 일부 Collect된 것을 볼 수 있다.

Incremental GC를 사용하는 방법은 JVM 옵션에 -Xinc 옵션을 사용하면 된다.
Incremental GC는 많은 자원을 소모하고, Minor GC를 자주 일으키고, 그리고 Incremental GC를 사용한다고 Full GC가 없어지거나 그 횟수가 획기적으로 줄어드는 것은 아니다. 오히려 느려지는 경우가 많다. 필히 테스트 후에 사용하도록 하자.

※ Default GC이외의 알고리즘은 Application의 형태나 HW Spec(CPU수, Hyper threading 지원 여부), 그리고 JVM 버전(JDK 1.4.1이냐 1.4.2냐)에 따라서 차이가 매우 크다. 이론상으로는 실제로 성능이 좋아 보일 수 있으나, 운영환경에서는 여러 요인으로 인해서 기대했던 것만큼의 성능이 안나올 수 있기 때문에, 실환경에서 미리 충분한 테스트를 거쳐서 검증한 후에 사용해야 한다.

5. GC 로그의 수집과 분석방법

JVM에서는 GC 상황에 대한 로그를 남기기 위해서 옵션을 제공하고 있다.

Java 옵션에 -verbosegc라는 옵션을 주면되고 HP Unix의 경우 -verbosegc -Xverbosegc 옵션을 주면 좀더 자세한 GC정보를 얻을 수 있다. GC 정보는 stdout으로 출력이 되기 때문에 ">" (redirection) 등을 이용해서 file에 저장해놓고 분석할 수 있다.

Example) java -verbosegc MyApplication

그럼 실제로 나온 GC로그를 어떻게 보는지를 알아보자.

```
[GC 40549K->20909K(64768K), 0.0484179 secs]
[GC 41197K->21405K(64768K), 0.0411095 secs]
[GC 41693K->22995K(64768K), 0.0846190 secs]
[GC 43283K->23672K(64768K), 0.0492838 secs]
[Full GC 43960K->1749K(64768K), 0.1452965 secs] ◀— Full GC
[GC 22037K->2810K(64768K), 0.0310949 secs]
[GC 23098K->3657K(64768K), 0.0469624 secs]
[GC 23945K->4847K(64768K), 0.0580108 secs]
```

GC Time
Total Heap Size
Heap size after GC
Heap size before GC

〈그림 8. 일반적인 GC 로그, Windows, Solaris〉

〈그림 8〉는 GC로그 결과를 모아놓은 내용이다. (실제로는 Application의 stdout으로 출력되는 내용과 섞여서 출력된다.)

Minor GC는 "[GC"로 표기되고, Full GC는 "[Full GC"로 표기된다.

그 다음 값은 Heap size before GC인데, GC 전에 Heap 사용량 (New/Young 영역 + Old 영역 + Perm 영역)의 크기를 나타낸다.

Heap size after GC는 GC가 발생한 후에 Heap의 사용량이다. Minor GC가 발생했을 때는 Eden과 Survivor 영역이 GC가 되므로 Heap size after GC는 Old 영역의 용량과 유사하다.(Minor GC에서 GC되지 않은 하나의 Survivor 영역내의 Object들의 크기도 포함해야 한다.)

Total Heap Size는 현재 JVM이 사용하는 Heap Memory 양이다. 이 크기는 Java에서 -ms와 -mx 옵션으로 조정이 가능한데. 예를 들어 -ms512m -mx1024m로 해놓으면 Java Heap은 메모리 사용량에 따라서 512~1024m 사이의 크기에서 적절하게 늘었다 줄었다한다. (이 늘어나는 기준과 줄어드는 기준은 (-XX:MaxHeapFreeRatio와 -XX:MinHeapFreeRation를 이용해서 조정할 수 있으나 JVM vendor에 따라서 차이가 나기때문에 각 vendor별 JVM 매뉴얼을 참고하기 바란다.) Parameter에 대한 이야기는 추후에 좀더 자세히 하도록 하자.

그 다음값은 GC에 소요된 시간이다.

〈그림 8〉의 GC로그를 보면 Minor GC가 일어날 때마다 약 20,000K 정도의 Collection이 일어난다. Minor GC는 Eden과 Suvivor 영역 하나를 GC하는 것이기 때문에 New/Young 영역을 20,000Kbyte 정도로 생각할 수 있다.

Full GC일 때를 보면 약44,000Kbyte에서 1,749Kbyte로 GC가 되었음을 볼 수 있다. Old 영역에 큰 데이타가 많지 않은 경우이다. Data를 많이 사용하는 Application의 경우 전체 Heap이 512이라고 가정할 때, Full GC 후에도 480M 정도로 유지되는 경우가 있다. 이런 경우에는 실제로 Application에서 Memory를 많이 사용하고 있다고 판단할 수 있기 때문에 전체 Heap Size를 늘려줄 필요가 있다.

이렇게 수집된 GC로그는 다소 보기가 어렵기 때문에, 좀더 쉽게 분석할 수 있게 하기 위해서 GC로그를 awk 스크립트를 이용해서 정제하면 분석이 용이하다.

〈표 2. gc.awk 스크립트〉

```
BEGIN{
  printf("Minor\tMajor\tAlive\tFree\n");
}
{
```

```
if( substr($0,1,4) == "[GC "){
  split($0,array," ");
  printf("%s\t0.0\t",array[3])
  split(array[2],barray,"K")
  before=barray[1]
  after=substr(barray[2],3)
  reclaim=before-after
  printf("%s\t%s\n",after,reclaim)
}
if( substr($0,1,9) == "[Full GC "){
  split($0,array," ");
  printf("0.0\t%s\t",array[4])
  split(array[3],barray,"K")
  before = barray[1]
  after = substr(barray[2],3)
  reclaim = before - after
  printf("%s\t%s\n",after,reclaim)
}
next;
}
```

이 스크립트를 작성한 후에 Unix의 awk 명령을 이용해서

% awk -f gc.awk GC 로그파일명

을 실행하면 아래〈표 3〉와 같이 정리된 형태로 GC 로그만 추출하여 보여준다.

〈표 3. gc.awk 스크립트에 의해서 정재된 로그〉

Minor	Major	Alive	Freed
0.0484179	0.0	20909	19640
0.0411095	0.0	21405	19792
0.0846190	0.0	22995	18698
0.0492838	0.0	23672	19611
0.0	0.1452965	1749	42211
0.0310949	0.0	2810	19227
0.0469624	0.0	3657	19441
0.0580108	0.0	4847	19098

Minor와 Major는 각각 Minor GC와 Full GC가 일어 날때 소요된 시간을 나타내며, Alive는 GC 후에 남아있는 메모리 양, 그리고 Freed는 GC에 의해서 collect된 메모리 양이다.

이 로그파일은 excel 등을 이용하여 그래프 등으로 변환해서 보면 좀더 다각적인 분석이 가능해진다.

※ JDK 1.4에서부터는 -XX:+PrintGCDetails 옵션이 추가되어서 좀더 자세한 GC정보를 수집할 수 있다.

※ HP JVM의 GC Log 수집

HP JVM은 전체 heap 뿐 아니라 -Xverbosegc 옵션을 통해서 Perm, Eden, Old등의 모든 영역에 대한 GC정보를 좀더 정확하게 수집할 수 있다.

Example) java -verbosegc -Xverbosegc MyApplication 〈— (HP JVM Only)

HP JVM의 GC 정보는 18개의 필드를 제공하는데 그 내용을 정리해보면 〈표 4〉와 같다.

〈GC : %1 %2 %3 %4 %5 %6 %7 %8 %9 %10 %11 %12 %13 %14 %15 %16 %17 %18 〉

〈표 4. HP JVM GC 로그 필드별 의미〉

필드	의미
%1	GC가 일어난 이유를 나타냄 -1:Minor GC 0~6 : Full GC (0:Call to System.gc, 1:Old Generation Full,2: Perm Generation Full,3:Train Generation Full,4:Old generation expanded on last scavenge,5:Old generation tool full to scavenge,6:FullGCAlot)
%2	GC가 시작된 시간 (Application이 시작된 시간을 기준으로 sec)
%3	GC invocation. Counts of Scavenge and Full GCs are maintained separately
%4	Size of the object allocation request that forced the GC in bytes
%5	Tenuring threshold - determines how long the new born object remains the New Generation
%06|%07|%08	Eden Before | After | Capacity
%09|%10|%11	Survivor Generation Before | After | Capacity
%12|%13|%14	Old Generation Before | After | Capacity
%15|%16|%17	Perm Generation Before | After | Capacity
%18	Time taken in seconds to finish the gc

이 로그를 직접 보면서 분석하기는 쉽지가 않다. 그래서, HP에서는 좀더 Visual한 환경에서 분석이 가능하도록 HPJtune이라는 툴을 제공한다. 다음 URL에서 다운로드 받을 수 있다.

http://www.hp.com/products1/unix/java/java2/hpjtune/index.html

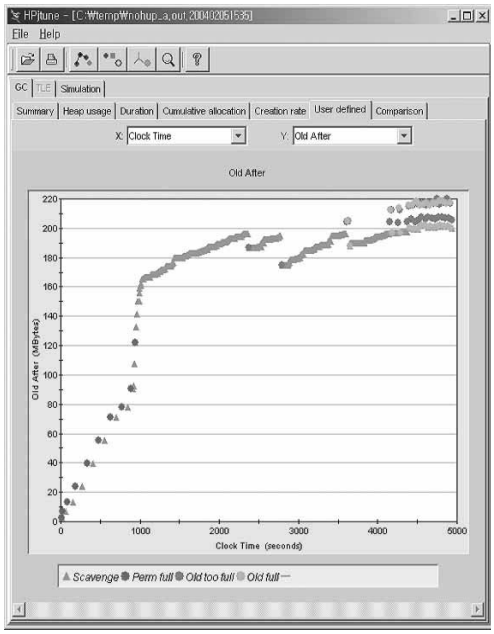

〈그림 9. HP Jtune을 이용해서 GC 후 Old 영역의 변화 추이를 모니터링하는 화면 〉

6. GC 관련 Parameter

GC관련 설정값을 보기 전에 앞서서 -X와 -XX 옵션에 대해서 먼저 언급하자. 이 옵션들은 표준 옵션이 아니라, 벤더별 JVM에서 따로 제공하는 옵션이기 때문에, 예고 없이 변경되거나 없어질 수 있으므로, 사용 전에 미리 JVM 벤더 홈페이지에서 체크한 후 사용해야한다.

1) 전체 Heap Size 조정 옵션

전체 Heap size는 -ms와 -mx로 Heap 사이즈의 영역을 조정할 수 있다. 예를 들어 -ms512m -mx1024m로 설정하면 JVM은 전체 Heap size를 application의 상황에 따라서 512m~1024m byte 사이에서 사용하게 된다. 〈그림 2〉의 Total heap size 메모리가 모자를 때는 heap을 늘리고, 남을 때는 heap을 줄이는 heap growing과 shirinking 작업을 수행하는데, 메모리 변화량이 큰 애플리케이션이 아니라면 이 min heap size와 max heap size는 동일하게 설정하는 것이 좋다. 일반적으로 1GB까지의 Heap을 설정하는데에는 문제가 없으나, 1GB가 넘는 대용량 메모리를 설정하고자 할 경우에는 별도의 JVM 옵션이 필요한 경우가 있기 때문에 미리 자료를 참고할 필요가 있다.

※ IBM AIX JVM의 경우
%export LDR_CNTRL=MAXDATA=0x10000000
%java -Xms1500m -Xmx1500m MyApplication

2) Perm size 조정 옵션

Perm Size는 앞에서도 설명했듯이, Java Application 자체(Java class etc..)가 로딩되는 영역이다. J2EE application의 경우에는 application 자체의 크기가 큰 편에 속하기 때문에, Default로 설정된 Perm Size로는 application class가 loading되기에 모자란 경우가 대부분이어서 WAS start초기나, 가동 초기에 Out Of Memory 에러를 유발하는 경우가 많다.

PermSize는 -XX:MaxPermSize=128m 식으로 지정할 수 있다.
일반적으로 WAS에서 PermSize는 64~256m 사이가 적절하다.

3) New 영역과 Old 영역의 조정

New 영역은 -XX:NewRatio=2에 의해서 조정이 된다.
NewRatio Old/New Size의 값이다. 전체 Heap Size가 768일 때, NewRatio=2이면 New 영역이 256m, Old 영역이 512m로 설정이 된다.
JVM 1.4.X에서는 -XX:NewSize=128m 옵션을 이용해서 직접 New 영역의 크기를 지정하는 것이 가능하다.

4) Survivor 영역 조정 옵션

-XX:SurvivorRatio=64 (eden/survivor 의 비율) 64이면 eden이 128m일 때, survivor 영역은 2m가 된다.

5) -server와 -client 옵션

JVM에는 일반적으로 server와 client 두 가지 옵션을 제공한다.
결론만 말하면 server 옵션은 WAS와 같은 Server환경에 최적화

된 옵션이고, client옵션은 워드프로세서와 같은 client application에 최적화된 옵션이다. 언뜻 보기에는 단순한 옵션 하나로 보일 수 있지만, 내부에서 돌아가는 hotspot compiler에 대한 최적화 방법과 메모리 구조자체가 아예 틀리다.

O -server 옵션

server용 application에 최적화된 옵션이다. Server application은 boot up 시간 보다는 user에 대한 response time이 중요하고, 많은 사용자가 동시에 사용하기 때문에 session등의 user data를 다루는 게 일반적이다. 그래서 server 옵션으로 제공되는 hotspot compiler는 java application을 최적화 해서 빠른 response time을 내는데 집중되어 있다.

또한 메모리 모델 역시, 서버의 경우에는 특정 사용자가 서버 운영시간동안 계속 서버를 사용하는 게 아니기 때문에 (Login하고, 사용한 후에는 Logout되기 때문에..) 사용자에 관련된 객체들이 오래 지속되는 경우가 드물다. 그래서 상대적으로 Old영역이 작고 New 영역이 크게 배정된다. 〈그림 10. 참조〉

O -client 옵션

client application은 워드프로세서처럼 혼자 사용하는 application이다. 그래서 client application은 response time보다는 빨리 기동되는 데에 최적화가 되어 있다. 또한 대부분의 client application을 구성하는 object는GUI Component와 같이 application이 종료될 때까지 남아있는 object의 비중이 높기 때문에 상대적으로 Old영역의 비율이 높다.

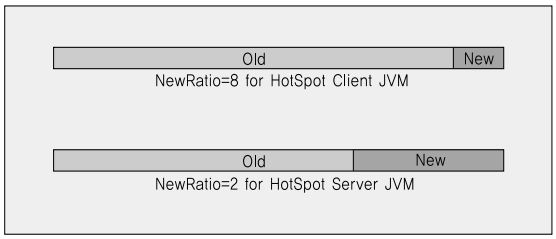

〈그림 10. -server와 -client 옵션에 따른 JVM Old와 New영역〉

이 두 옵션은 가장 간단한 옵션이지만, JVM의 최적화에 아주 큰 부분을 차지하고 있는 옵션이기 때문에, 반드시 Application의 성격에 맞춰서 적용하기 바란다.
(※ 참고로, SUN JVM은 default가 client, HPJVM는 default가 server로 세팅되어 있다.)

O GC 방식에 대한 옵션

GC 방식에 대한 옵션은 앞에서도 설명했지만, 일반적인 GC방식이외에, Concurrent GC, Parallel GC, Inceremental GC와 같이 추가적인 GC Algorithm이 존재한다. 옵션과 내용은 앞장에서 설명한 "다양한 GC알고리즘"을 참고하기 바란다.

7. JVM GC 튜닝

그러면 이제부터 지금까지 설명한 내용을 기반으로 실제로 JVM 튜닝을 어떻게 하는지 알아보도록 하자.

STEP 1. Application의 종류와 튜닝 목표값을 결정한다.

JVM 튜닝을 하기위해서 가장 중요한 것은 JVM 튜닝의 목표를 설정하는 것이다. 메모리를 적게 쓰는것이 목표인지, GC 횟수를 줄이는 것이 목표인지, GC에 소요되는 시간이 목표인지, Application의 성능(Throughput or response time) 향상인지를 먼저 정의한 후에, 그 목표치에 근접하도록 JVM Parameter를 조정하는 것이 필요하다.

STEP 2. Heap size와 Perm size를 설정한다.

-ms와 -mx 옵션을 이용해서 Heap Size를 정한다. 일반적으로 server application인 경우에는 ms와 mx 사이즈를 같게 하는 것이 Memory의 growing과 shrinking에 의한 불필요한 로드를 막을 수 있어서 권장할만하다.

ms와 mx 사이즈를 다르게 하는 경우는 Application의 특정시간대에 memory 사용량이 많은 Application에 효과적이다.
PermSize는 JVM vendor에 따라 다소 차이가 있으나 일반적으로 16m 정도이다. Client application의 경우에는 문제가 없을 수 있지만, J2EE Server Application의 경우 64~128m 사이로 사용이 된다.

Heap Size와 Perm Size는 아래 과정을 통해서 적정 수치를 얻어가야 한다.

STEP 3. 테스트 & 로그 분석.

JVM Option에 GC 로그를 수집하기 위한 -verbosegc 옵션을 적용한다. (HP의 경우 -Xverbosegc 옵션을 적용한다.)
LoadRunner나 MS Stress(무료로 MS社의 홈페이지에서 다운로

드 받을 수 있다.)와 같은 Stress Test툴을 통해서 Application에 Stress를 줘서 그 log를 수집한다. 튜닝에 있어서 가장 중요한 것은 목표산정이지만, 그만큼이나 중요 한것은 실제 Tuning한 Parameter가 Application에 어떤 영향을 주는지를 테스트하는 방법이 매우 중요하다. 그런 의미에서 적절한 Stress Tool의 선정과, Stress Test 시나리오는 정확한 Tuning을 위해서 매우 중요한 요인이다.

O Perm size 조정

아래 〈그림 11〉은 HP JVM에서 -Xverbosegc 옵션으로 수집한 GC log를 HP Jtune을 통해서 graph로 나타낸 그래프이다. 그림을 보면 Application이 startup되었을때 Perm 영역이 40m에서 시간이 지난 후에도 50m 이하로 유지되는 것을 볼 수 있다. 특별하게 동적 classloading 등이 수십 m byte가 일어나지 않는 등의 큰 변화요인이 없을 때, 이 application의 적정 Perm 영역은 64m로 판단할 수 있다.

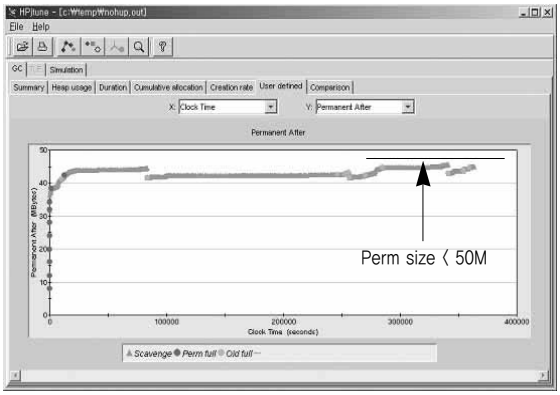

〈그림 11. GC 결과 중 Perm 영역 그래프〉

O GC Time 수행 시간 분석

다음은 GC에 걸린 시간을 분석해보자. 앞에 강좌 내용에서도 설명했듯이 GC Tuning에서 중요한 부분 중 하나가 GC에 소요되는 시간 특히 Full GC 시간이다.

지금부터 분석해 볼 Log는 모社의 물류 시스템의 WAS 시스템 GC Log이다. HP JVM을 사용하며, -server -ms512m -mx512m 옵션으로 기동되는 시스템이다.

〈그림 12〉를 보면 Peak 시간 (첫번째 동그라미) 14시간동안에 Full GC(동그란점)가 7번 일어난 것을 볼 수 있다. 각각에 걸린 시간은 2.5~6sec 사이이다.

여기서 STEP 1에서 설정한 AP Tuning의 목표치를 참고해야 하는데,

Full GC가 길게 일어나서 Full GC에 수행되는 시간을 줄이고자 한다면 Old 영역을 줄이면 Full GC가 일어나는 횟수는 늘어나고, 반대로 Full GC가 일어나는 시간을 줄어들 것이다.

반대로 Full GC가 일어나는 횟수가 많다면, Old 영역을 늘려주면 Full GC가 일어나는 횟수는 상대적으로 줄어들 것이고 반대로 Full GC 수행시간이 늘어날 것이다.

특히 Server Application의 경우 Full GC가 일어날 때는 JVM자체가 멈춰버리기 때문에, 〈그림 12〉의 instance는 14시간동안 총 7번 시스템이 멈추고, 그때마다 2.5~6sec가량 시스템이 response를 못하는 상태가 된 것이다. 그래서 멈춘 시간이 고객이 납득할만한 시간인지를 판단해야 하고, 거기에 적절한 Tuning을 해야 한다.

Server Application에서 Full GC를 적게 일어나게 하고, Full GC 시간을 양쪽다 줄이기 위해서는 Old 영역을 적게한후에, 여러 개의 Instance를 동시에 띄어서 Load Balancing을 해주면, Load가 분산되기 때문에 Full GC가 일어나는 횟수가 줄어들테고, Old 영역을 줄였기 때문에, Full GC에 드는 시간도 줄어들것이다. 또한 각각의 Full GC가 일어나는 동안 하나의 서버 instance가 멈춰져 있어도, Load Balancing이 되는 다른 서버가 response를 하고 있기 때문에, Full GC로 인한 Application이 멈추는 것에 의한 영향을 최소화 할 수 있다.

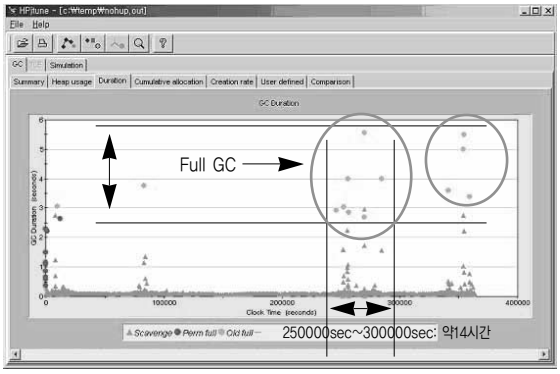

〈그림 12. GC 소요시간〉

데이타에 따라서 GC Tuning을 진행한 후에는 다시 Stress Test를 진행해서 응답시간과 TPS(Throughput Per Second)를 체크해서 어떤 변화를 주었는지를 반드시 체크해 봐야한다.

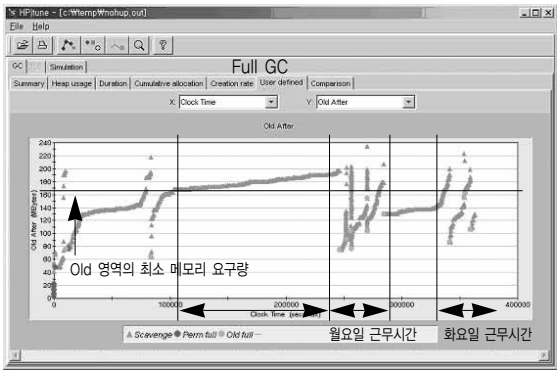

〈그림 13. GC후의 Old 영역〉

〈그림 13〉은 GC 후에 Old 영역의 메모리 변화량을 나타낸다

금요일 업무시간에 메모리 사용량이 올라가다가. 주말에 가서 완만한 곡선을 그리는 것을 볼 수 있다. 월요일 근무시간에 메모리 사용량이 매우 많고, 화요일에도 어느 정도 메모리 사용량이 있는것을 볼 수 있다. 월요일에 메모리 사용량이 많은 것을 볼 때, 이 시스템의 사용자들이 월요일에 시스템 사용량이 많을 수 있다고 생각할 수 있고, 또는 다른 주의 로그를 분석해 봤을 때 이 주만 월요일 사용량이 많았다면, 특별한 요인이나 Application 변경 등이 있었는지를 고려해 봐야 할 것이다.

이 그래프만을 봤을 때 Full GC가 일어난후에도 월요일 근무시간을 보면 Old 영역이 180M를 유지하고 있는 것을 볼 수 있다. 이 시스템의 Full GC 후의 Old 영역은 80M~180M를 유지하는 것을 볼 수 있다. 그래서 이 시스템은 최소 180M이상의 Old 영역을 필요로 하는 것으로 판단할 수 있다.

STEP 4. Parameter 변경.

STEP 3에서 구한 각 영역의 허용 범위를 기준으로 Old영역과 New 영역을 적절하게 조절한다.

PermSize와 New영역의 배분 (Eden, Survivor)영역 등을 조정한다.

PermSize는 대부분 Log에서 명확하게 나타나기 때문에, 크게 조정이 필요가 없고 New 영역내의 Eden과 Survivor는 거의 조정하지 않는다. 가장 중요한 것은 Old 영역과 New 영역의 비율을 어떻게 조정하는가가 관건이다.

이 비율을 결정하면서, STEP 1에서 세운 튜닝 목표에 따라서 JVM의 GC Algorithm을 적용한다. GC Algorithm을 결정하는 기본적인 판단 내용은 아래와 같다.

향상 포인트	GC Algorithm	비고
Performance (속도) 중시	Parallel GC	JVM 1.4.2 이상 4CPU 이상
Responsiveness (응답성) 중시	Concurrent GC	JVM 1.4.2 이상 4CPU 이상
Responsiveness (응답성) 중시	Incremental GC	JVM 1.4.2 이하 또는 4CPU 미만
일반	Default GC	JVM 1.4.2 이하 또는 4CPU 미만

이렇게 Parameter를 변경하면서 테스트를 진행하고, 다시 변경하고 테스트를 진행하는 과정을 거쳐서 최적의 Parameter와 GC Algorithm을 찾아내는 것이 JVM의 메모리 튜닝의 이상적인 절차이다.

지금까지 JVM의 메모리 구조와 GC 모델 그리고 GC 튜닝에 대해서 알아보았다.

정리하자면 GC 튜닝은 Application의 구조나 성격 그리고, 사용자의 이용 Pattern에 따라서 크게 좌우 되기 때문에, 얼마만큼의 Parameter를 많이 아느냐 보다는 얼마만큼의 테스트와 로그를 통해서 목표 값에 접근하느냐가 가장 중요하다.