Memory Management

단국대학교
컴퓨터학과
2009
백승재
ibanez1383@dankook.ac.kr
http://embedded.dankook.ac.kr/~ibanez1383

강의 목표

- 리눅스의 물리 메모리 관리기법 이해
  - ✓ 할당 / 해제 기법
- 리눅스의 가상 메모리 관리기법 이해
  - ✓ 할당 / 해제 기법
- 리눅스의 물리 메모리와 가상 메모리 연결/혹은 변환 기법 이해

가상 메모리 개념(1/4)

- 가상 메모리 개념
  - 프로그램이 적재되어 있는 물리 메모리와 프로그램의 수행 시 참조하는 가상 메모리를 구분
  - 가상 주소(virtual address)와 물리 주소(physical address)

- 간단한 C 프로그램 예

```
/* test.c */

#include <stdio.h>

int a,b;
int glob = 3;
char buf[100];

main(int argc, char *argv[])
{
    int i = 1;
    int local_var;

    a = i + 1;
    printf("value of a = %d\n",a);
}
```

가상 메모리 개념(2/4)

- test.c의 가상 메모리 구조

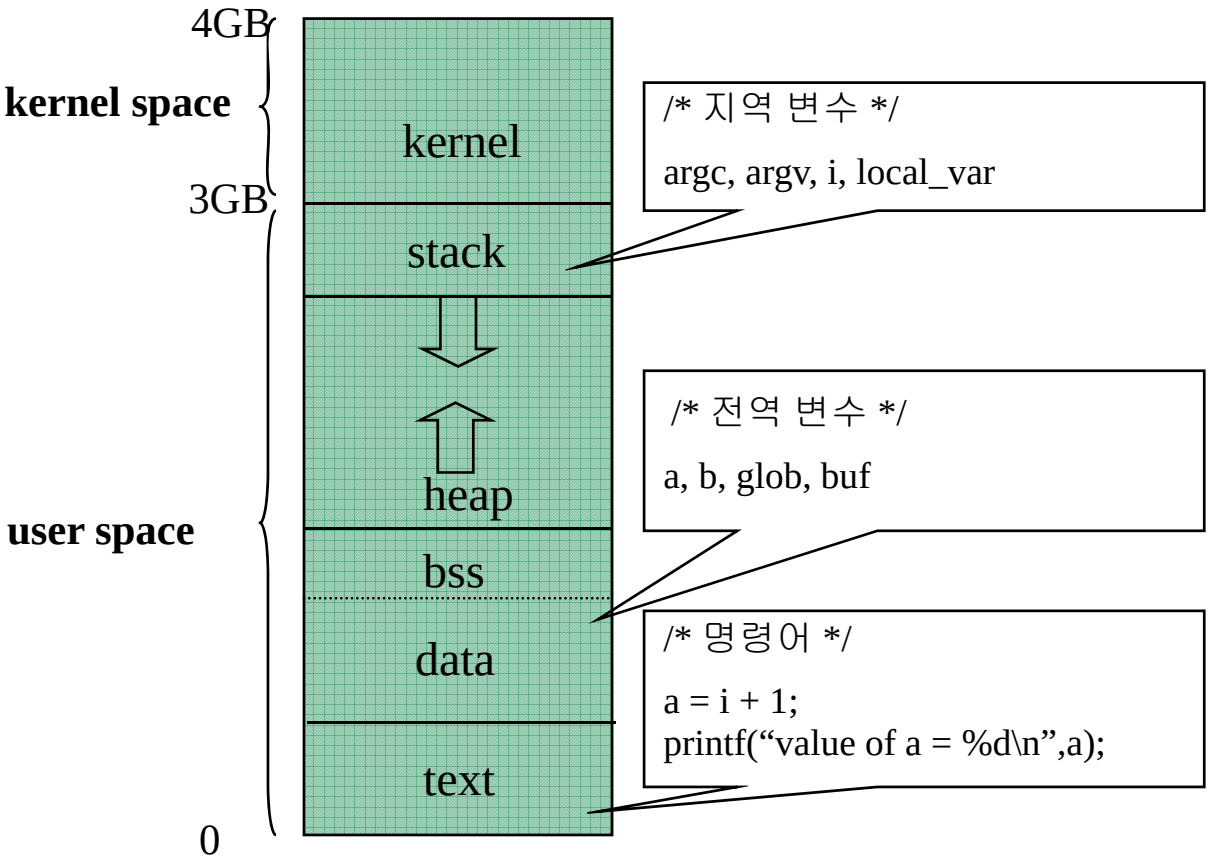

가상 메모리 개념(3/4)

- Linux 커널에서 가상 메모리 구조

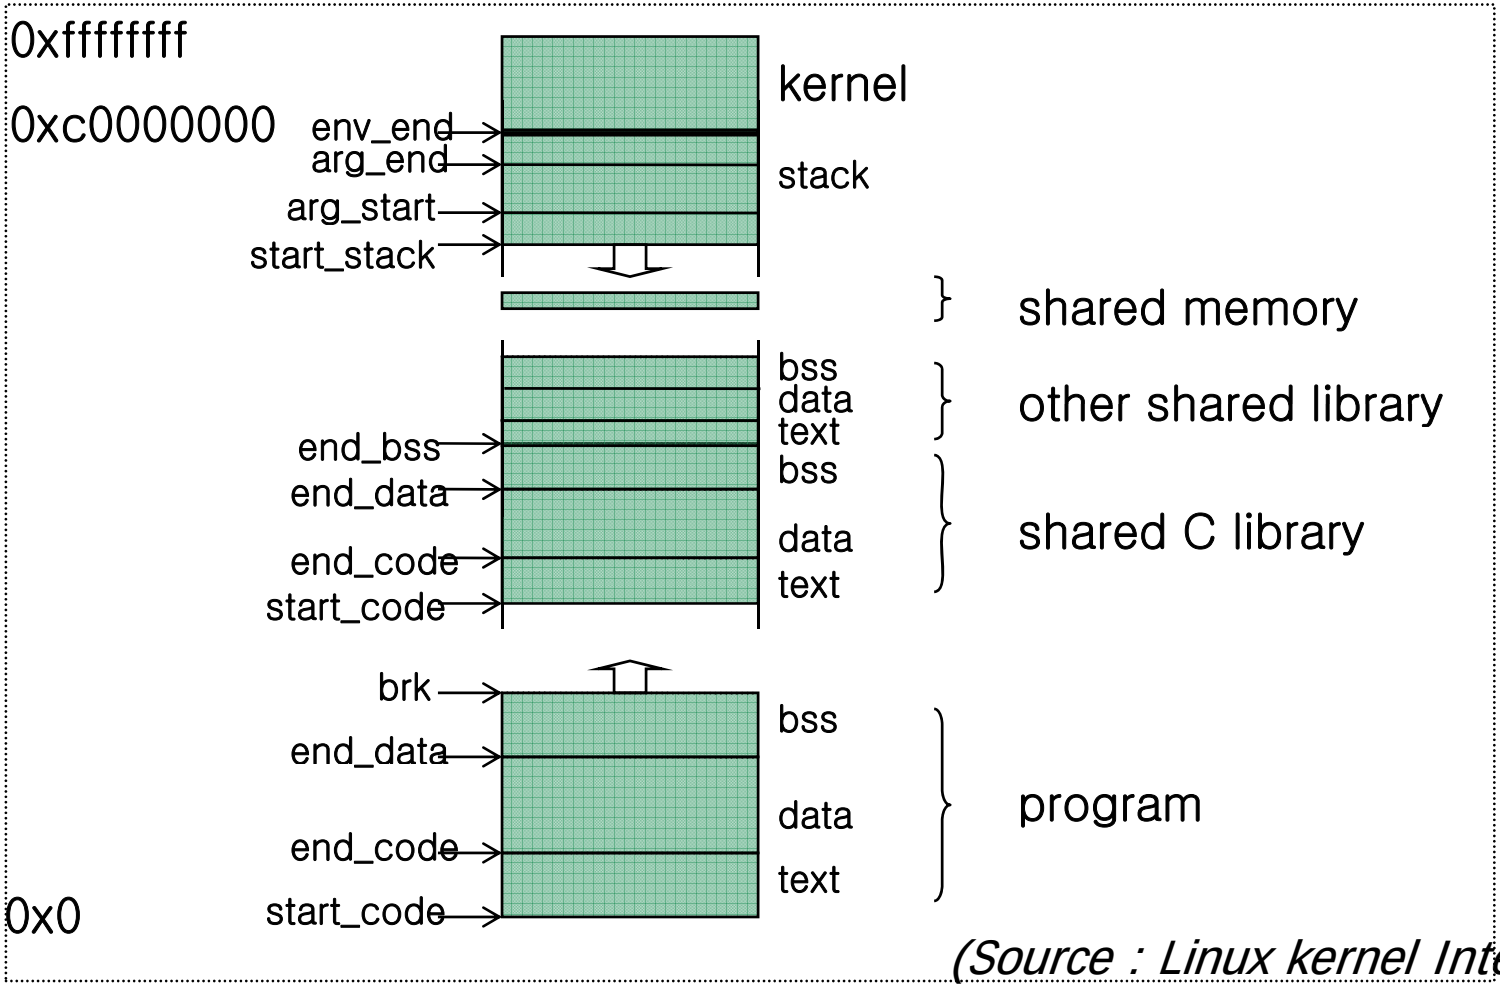

(Source : Linux kernel Internals)

가상 메모리 개념(4/4)

- 물리 메모리 구조
  - ✓ 물리 메모리는 고정된 크기의 기본 단위로 구분된다.
    - 기본 단위를 페이지 프레임(page frame)이라고 함. 보통 4/8KB

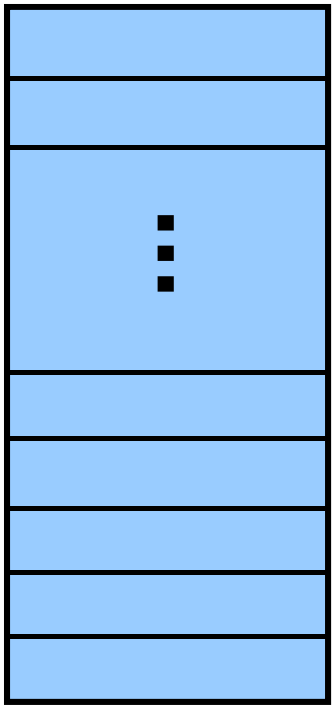

physical memory

물리 메모리의 기본 단위를 **page frame,** 가상 메모리의 기본 단위를 **page**라고 한다**!!**

Memory Model(1/2)

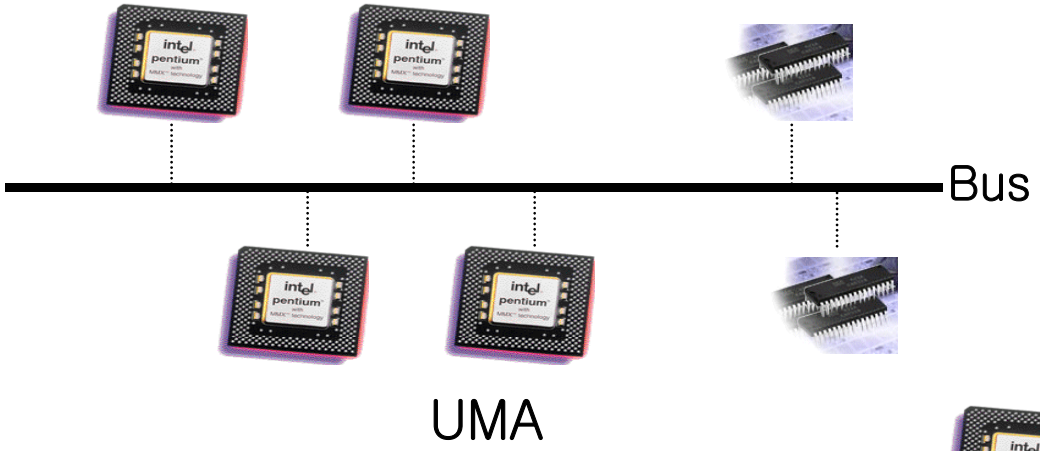

UMA

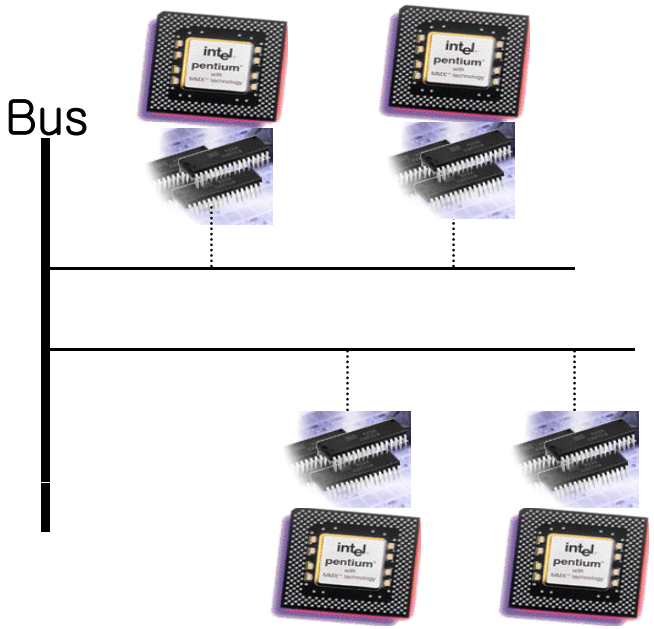

NUMA

(Source : Unix Internals)

Memory Model(2/2)

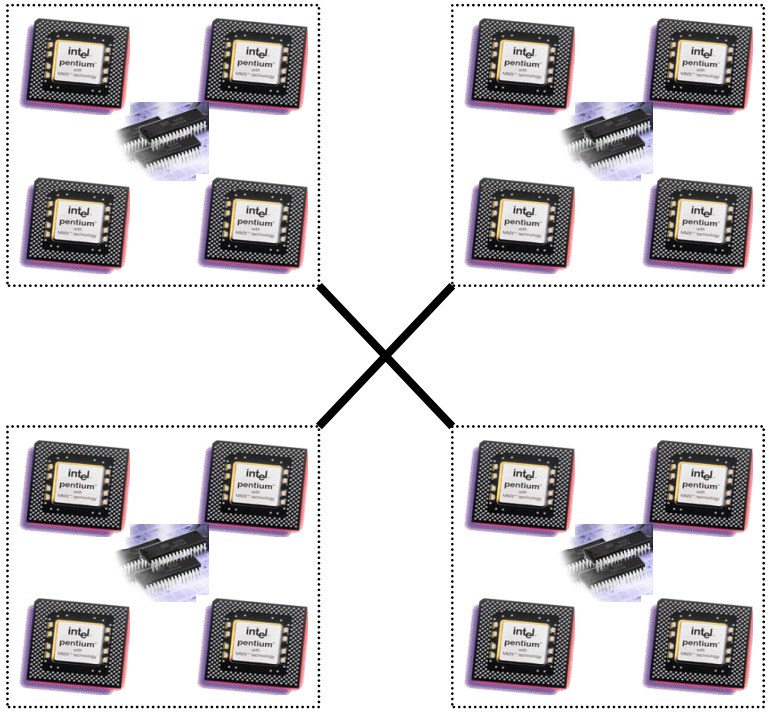

Hybrid NUMA

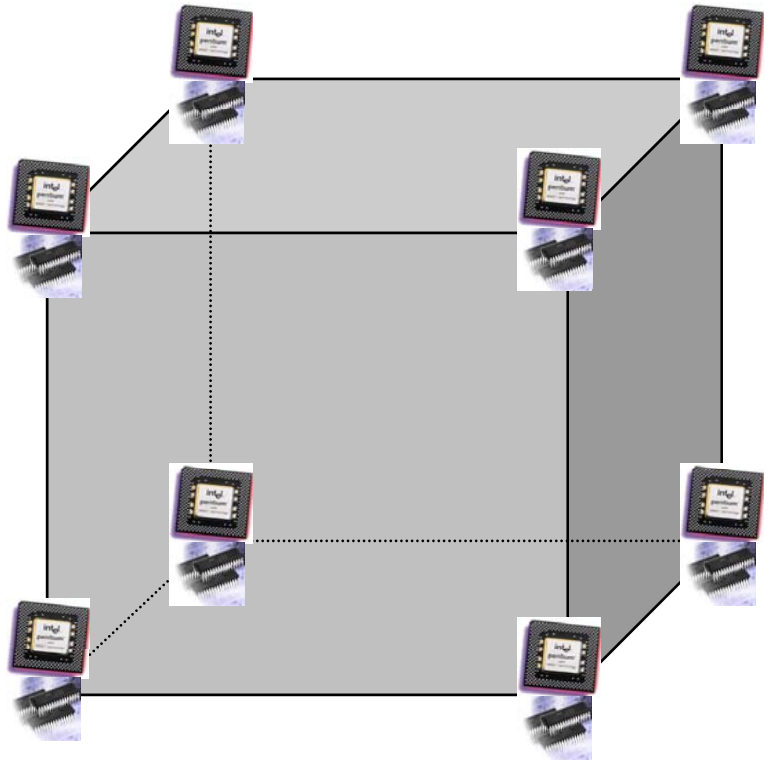

NORMA

(Source : Unix Internals)

Bank and Node

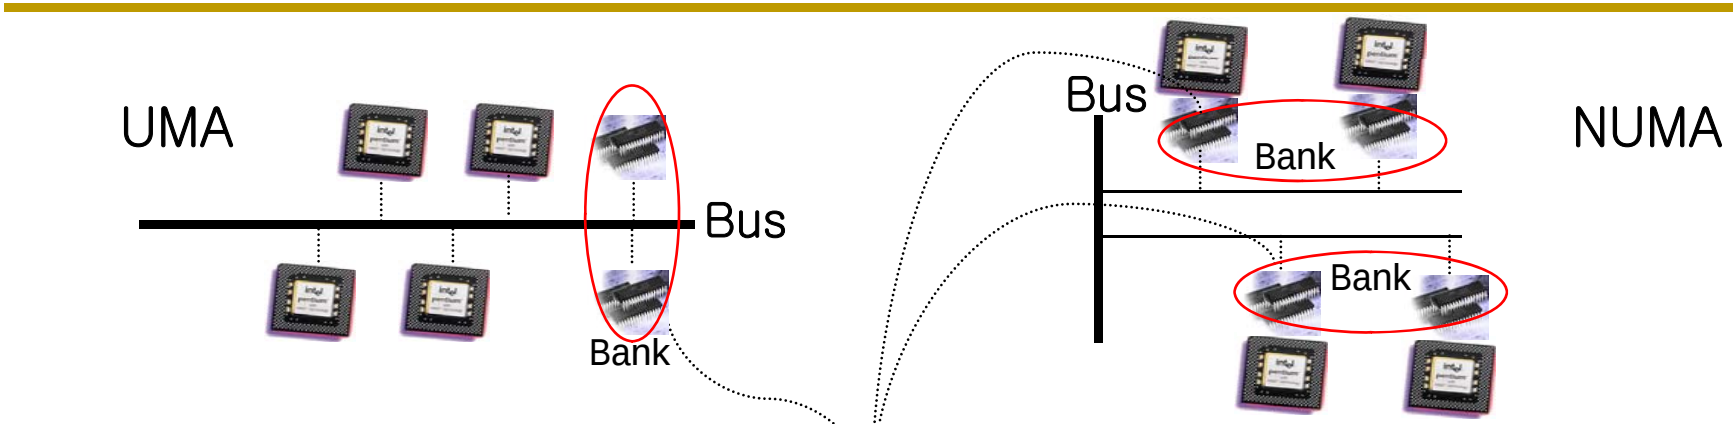

pg_data_t contig_page_data

Node

pg_data_t *pgdat_list

```
typedef struct pglist_data {
        zone_t                  node_zones[MAX_NR_ZONES];
        zonelist_t              node_zonelists[GFP_ZONEMASK+1];
        int                     nr_zones;
        struct page             *node_mem_map;
        unsigned long           *valid_addr_bitmap;
        struct bootmem_data     *bdata;
        unsigned long           node_start_paddr;
        unsigned long           node_start_mapnr;
        unsigned long           node_size;
        int                     node_id;
        struct pglist_data      *node_next;
} pg_data_t;
```

Node

.....

Node

NULL

NODE 자료 구조

```
typedef struct pglist_data{
        zone_t node_zones[MAX_NR_ZONES];
                // node를 위한 zone은 ZONE_HIGHMEM, ZONE_NORMAL, ZONE_DMA 3개이다.
                // 각 zone을 가리키기 위한 배열임
        zonelist_t node_zonelists[GFP_ZONEMASK+1];
                // ((0x0f=15)+1=16) 할당 시에 우선시 되는 zone 순서를 나타냄
                // free_area_init_core()에의해
                // mm/page_alloc.c내의 build_zonelists()가 호출되면 이 순서를 정렬해 놓는다
        int nr_zones;
                // 이 node에 몇개의 zone이있는지 나타내는 1~3사이의 값.
                // 예를 들어 어떤 CPU는 ZONE_DMA 에 해당되는 메모리 영역이 없을수도 있으므로 항상 3은 아니다
        struct page *node_mem_map;
                // node의 각 physical frame을 나타내는 struct page배 열의 첫번째 page임.
                // 이는 전역배열인 mem_map의 어딘가에 들어갈 것이다
        unsigned long *valid_addr_bitmap;
                // memory node상에서, 실제로 존재하지않는 'holes'를 나타내기 위한 BITMAP
                // 사실상, Sparc과 Sparc64에서만 사용되며 다른 arch에선 무시됨
        struct bootmem_data *bdata
                // boot memory allocator가 사용하는 필드
        unsigned long node_start_paddr;
                // node의 physical 한 시작 주소
                // unsigned long은 PAE(physical Address Extension)을 사용하는 IA32나
                // PPC440GP같은 PowerPC의 변종들에선 최적화되어 작동하지 않는다
                // 좀더 나은 방법은 PFN(Page Frame Number)를 기록하는 것이다.
                // PFN은 간단히 말해서 page-size단위로 계산되는 physical memory의 index이다
                // PFN은 보통 (page_phys_addr >> PAGE_SHIFT)로 정의 된다.
        unsigned long node_start_mapnr;
                // mem_map내에서의 page offset을 나타냄
                // 이 숫자는 ,mem_map과 lmem_map이라고 불리는 local mem_map사이의 page갯수를 계산하는,
                // free_area_init_core()에서 계산됨
        unsigned long node_size;
                // 이 node내의 총 page수
        int node_id;
                // 0에서 시작되는 Node ID(NID)
        struct pglist_data *node_next;
                // NULL로 끝나도록 되어있는, 다음 node를 가리키는 pointer
}pg_data_t;
```

Node and Zone

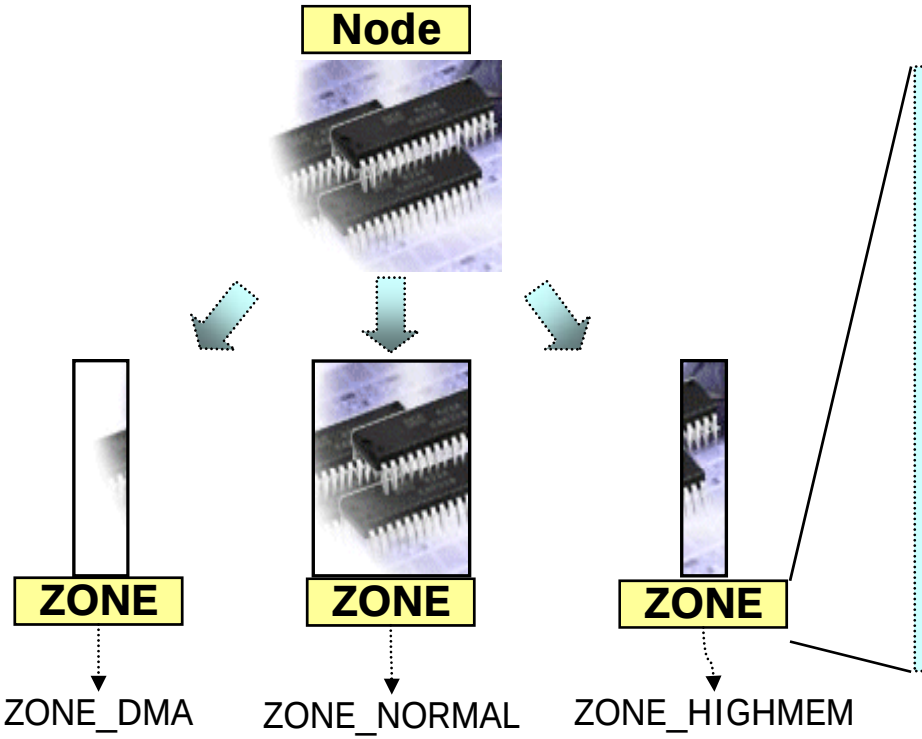


```
typedef struct zone_struct {
        spinlock_t              lock;
        unsigned long           free_pages;
        unsigned long           pages_min, pages_low, pages_high;
        int                     need_balance;
        free_area_t             free_area[MAX_ORDER];
        wait_queue_head_t       * wait_table;
        unsigned long           wait_table_size;
        unsigned long           wait_table_shift;
        struct pglist_data      *zone_pgdat;
        struct page             *zone_mem_map;
        unsigned long           zone_start_paddr;
        unsigned long           zone_start_mapnr;
        char                    *name;
        unsigned long           size;
} zone_t;
```

X86 System 에서는

ZONE_DMA ➔ 0 ~ 16M

ZONE_NORMAL ➔ 16 ~ 896M

ZONE_HIGHMEM ➔ 896 ~ end

Kernel Address Space(1/13)

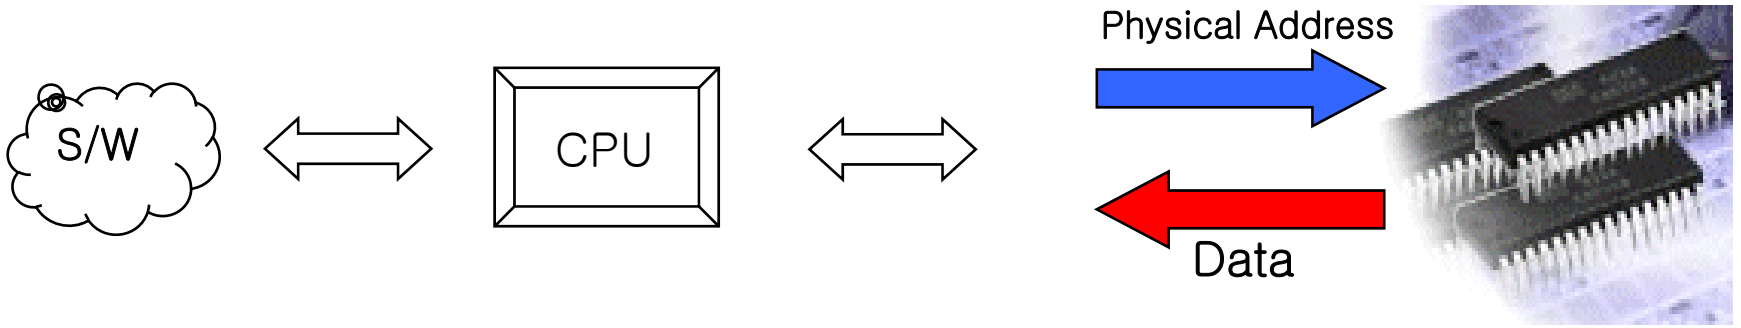

Kernel Address Space(2/13)

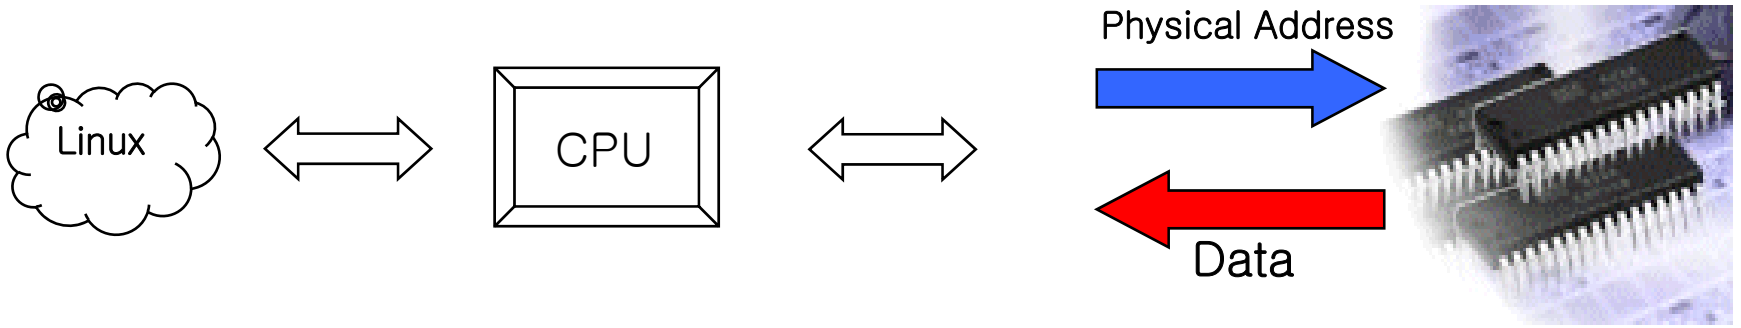

Kernel Address Space(3/13)

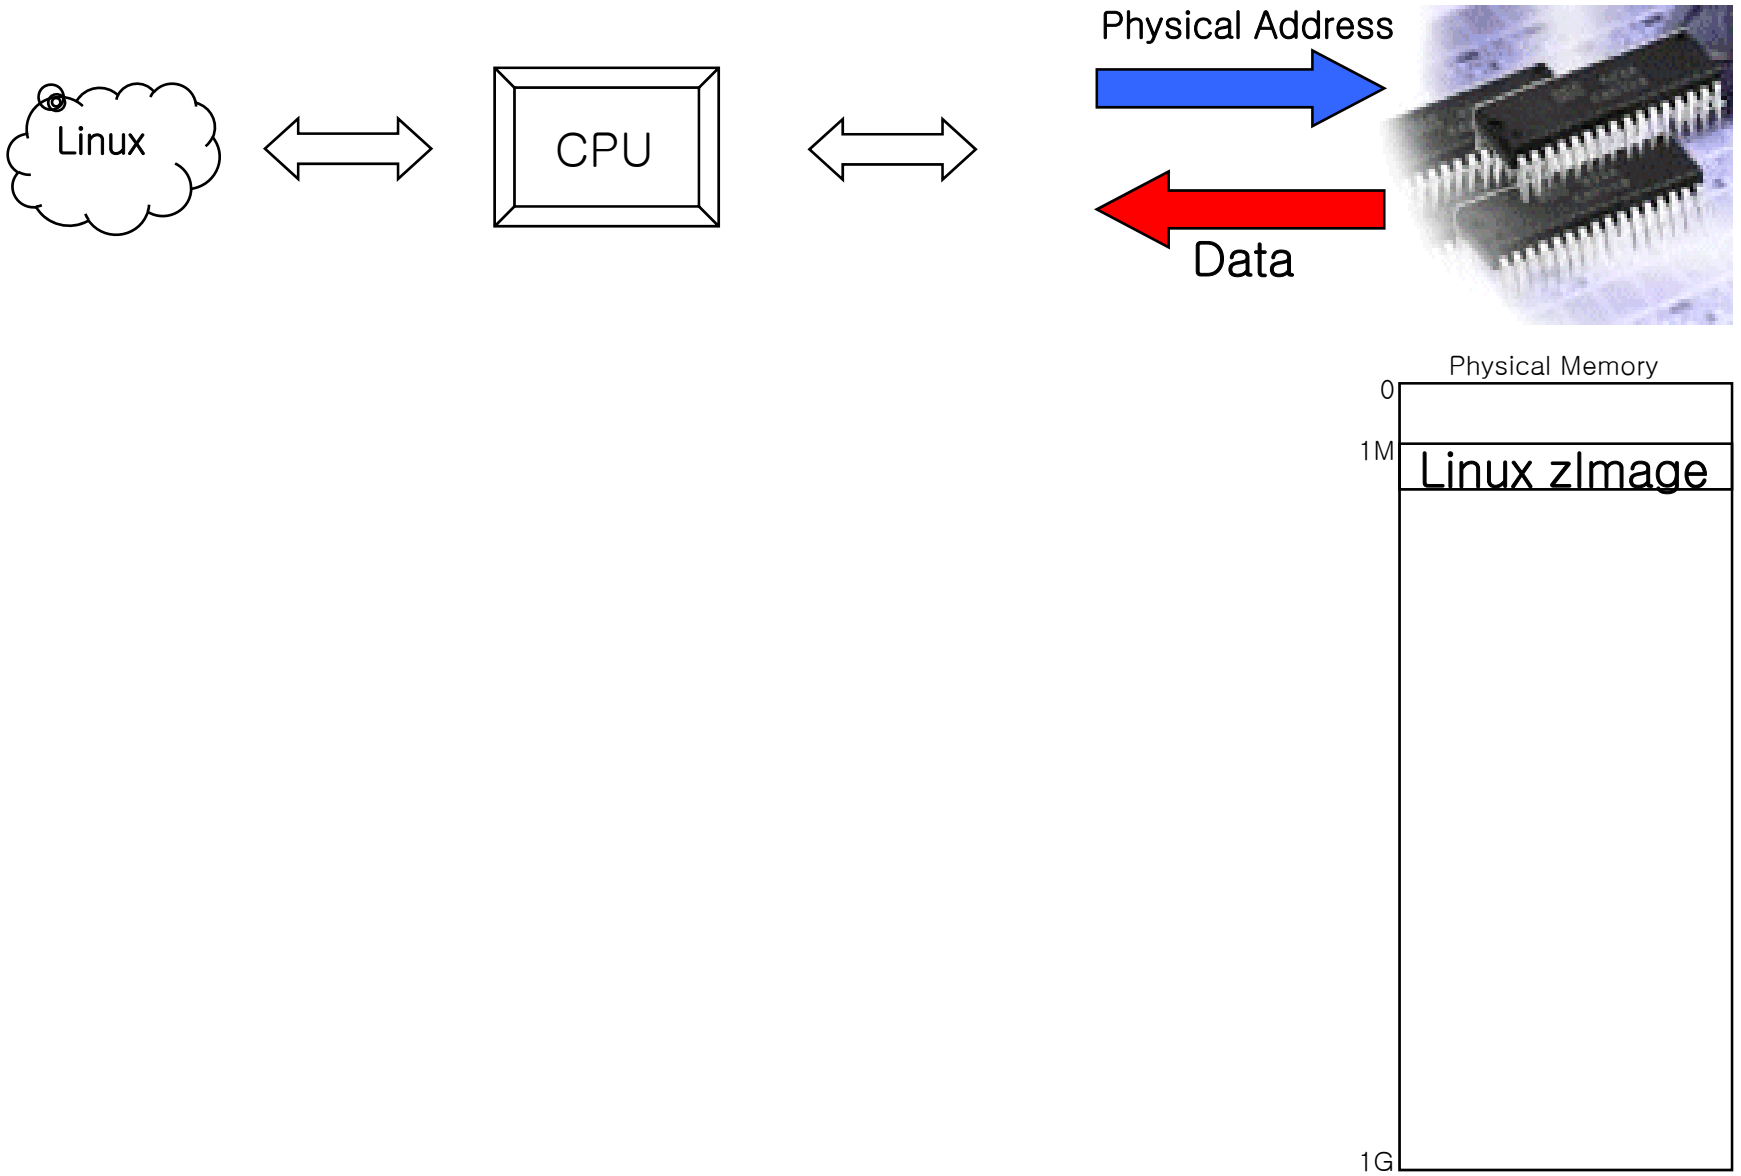

Kernel Address Space(4/13)

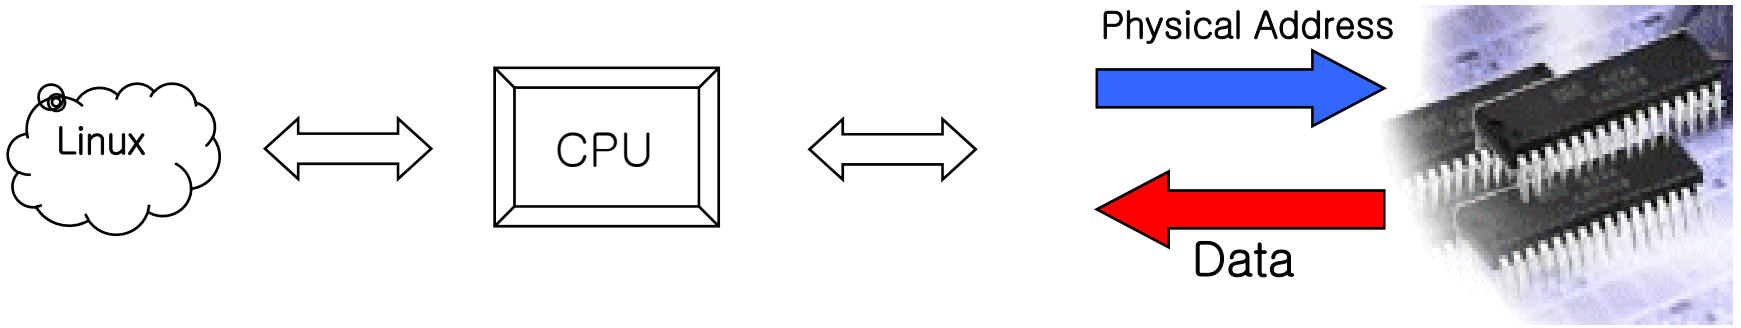

Kernel Address Space(5/13)

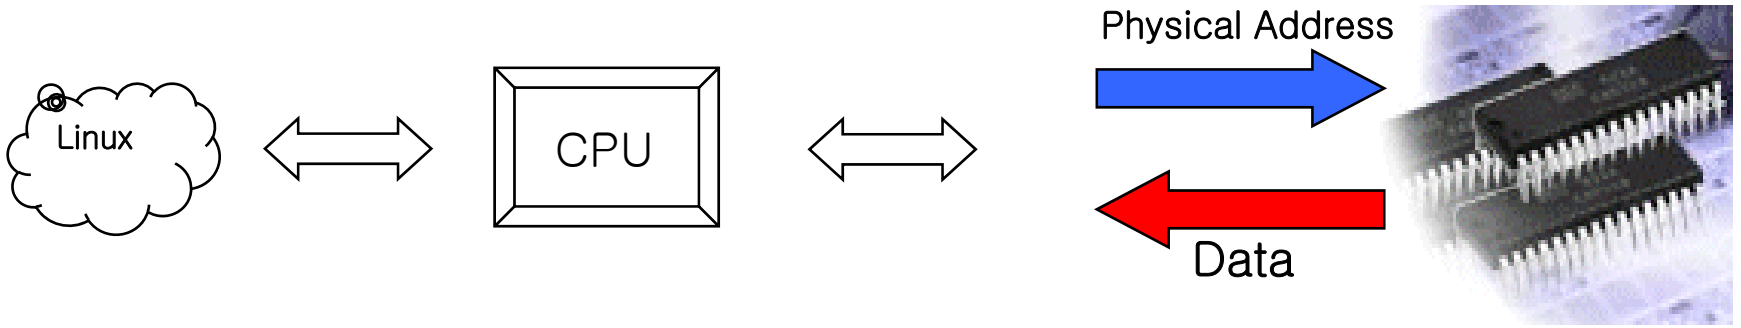

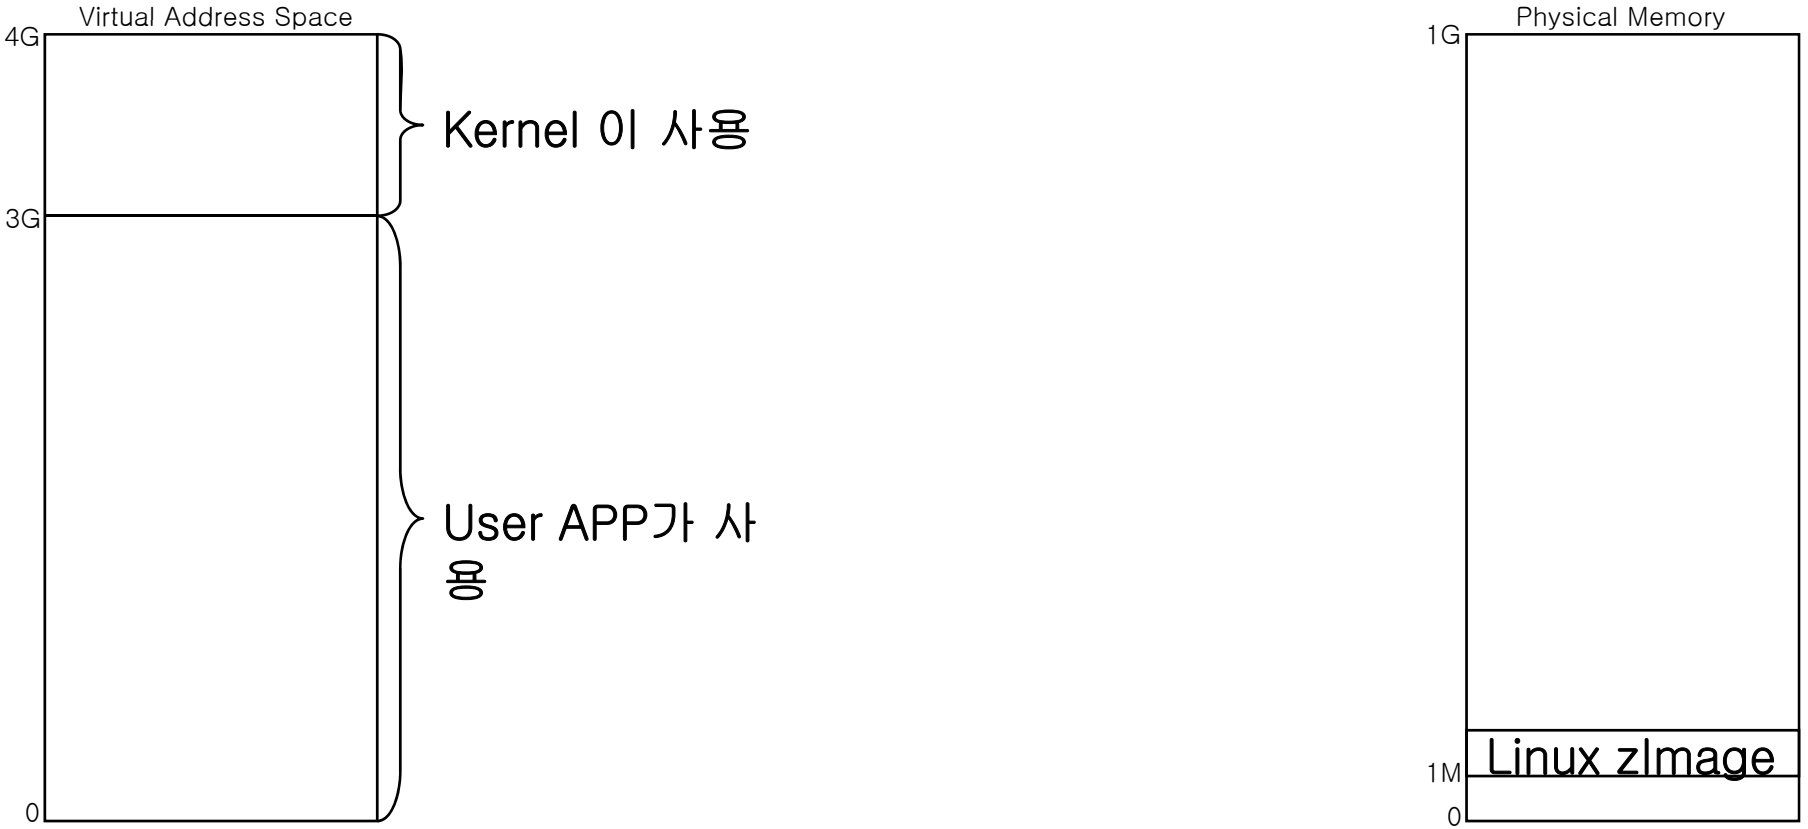

Kernel Address Space(6/13)

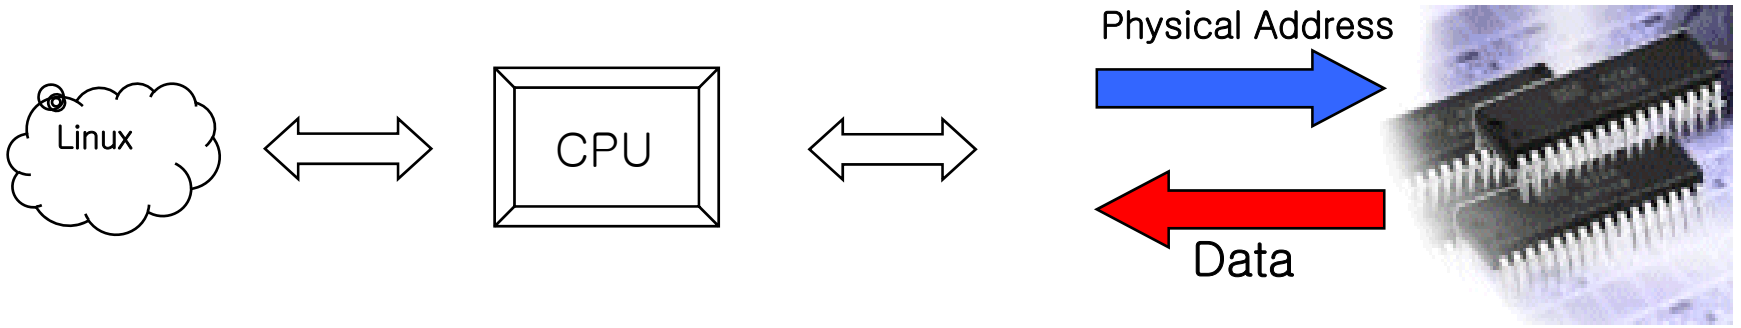

Kernel Address Space(7/13)

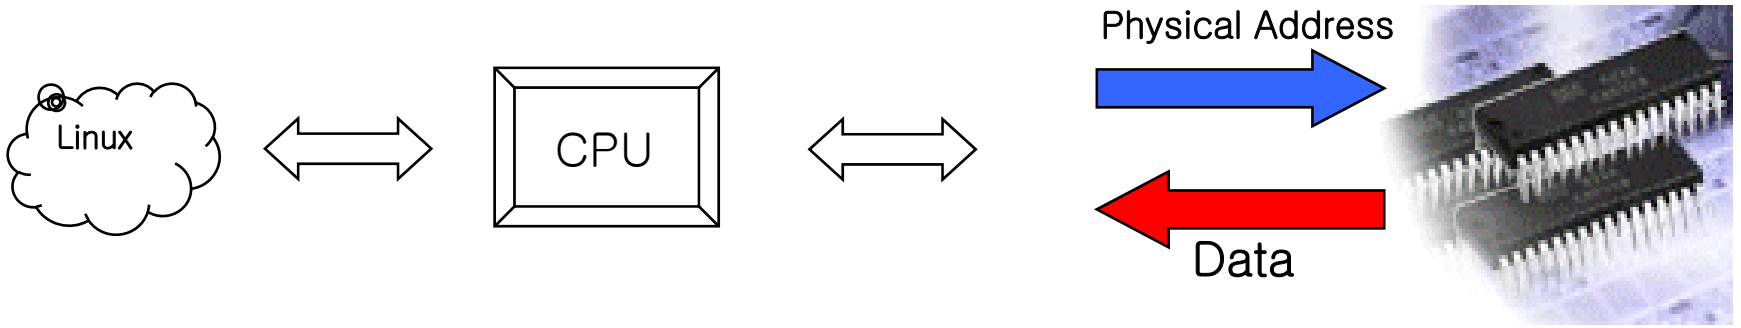

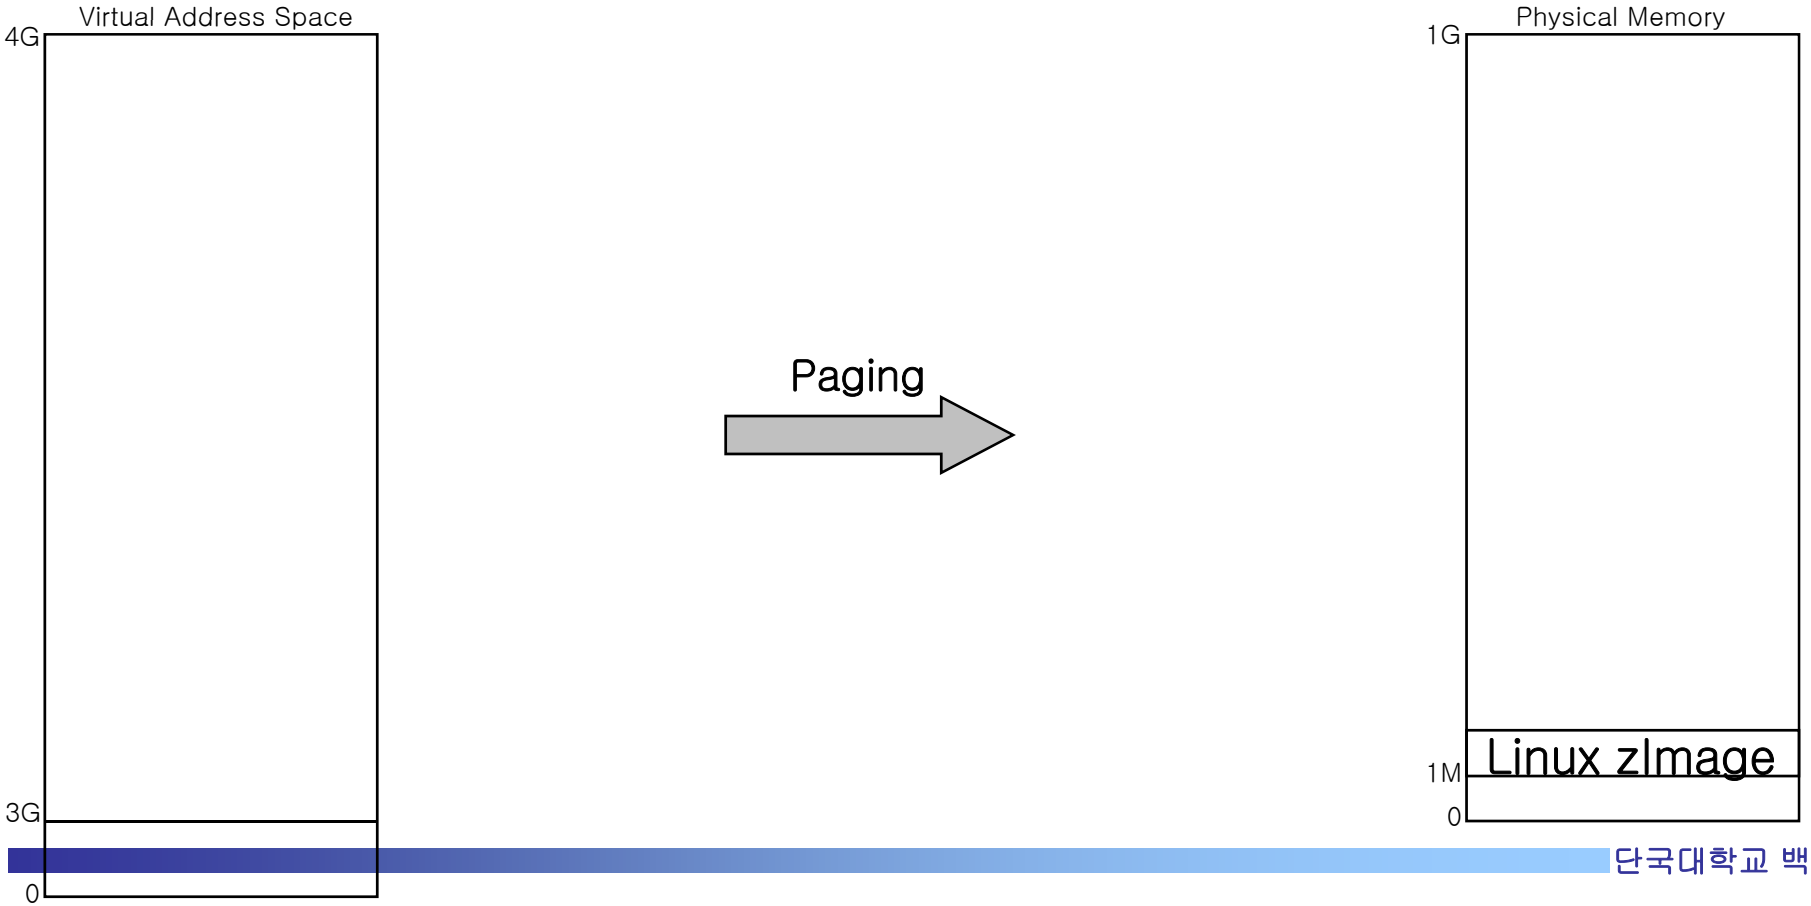

Kernel Address Space(8/13)

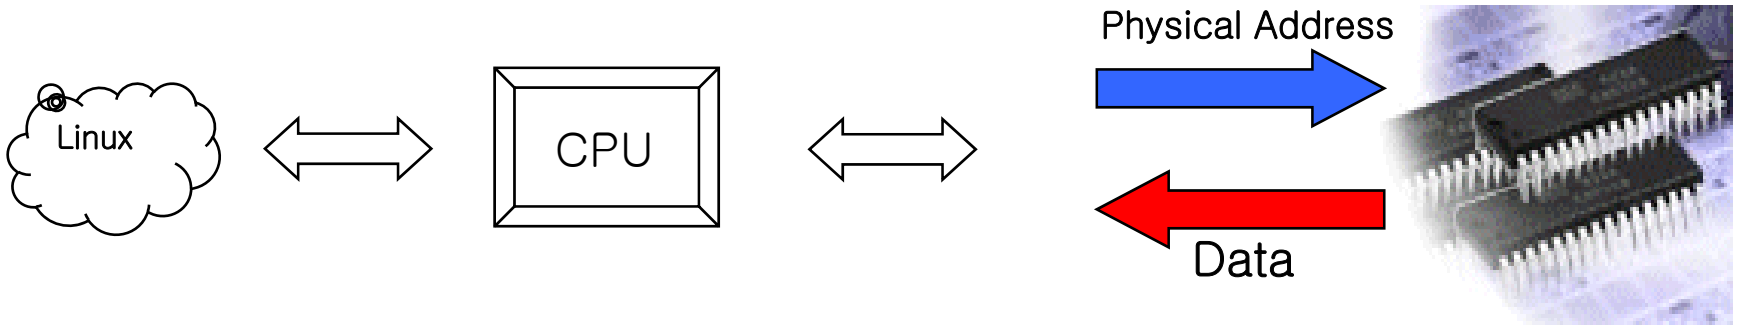

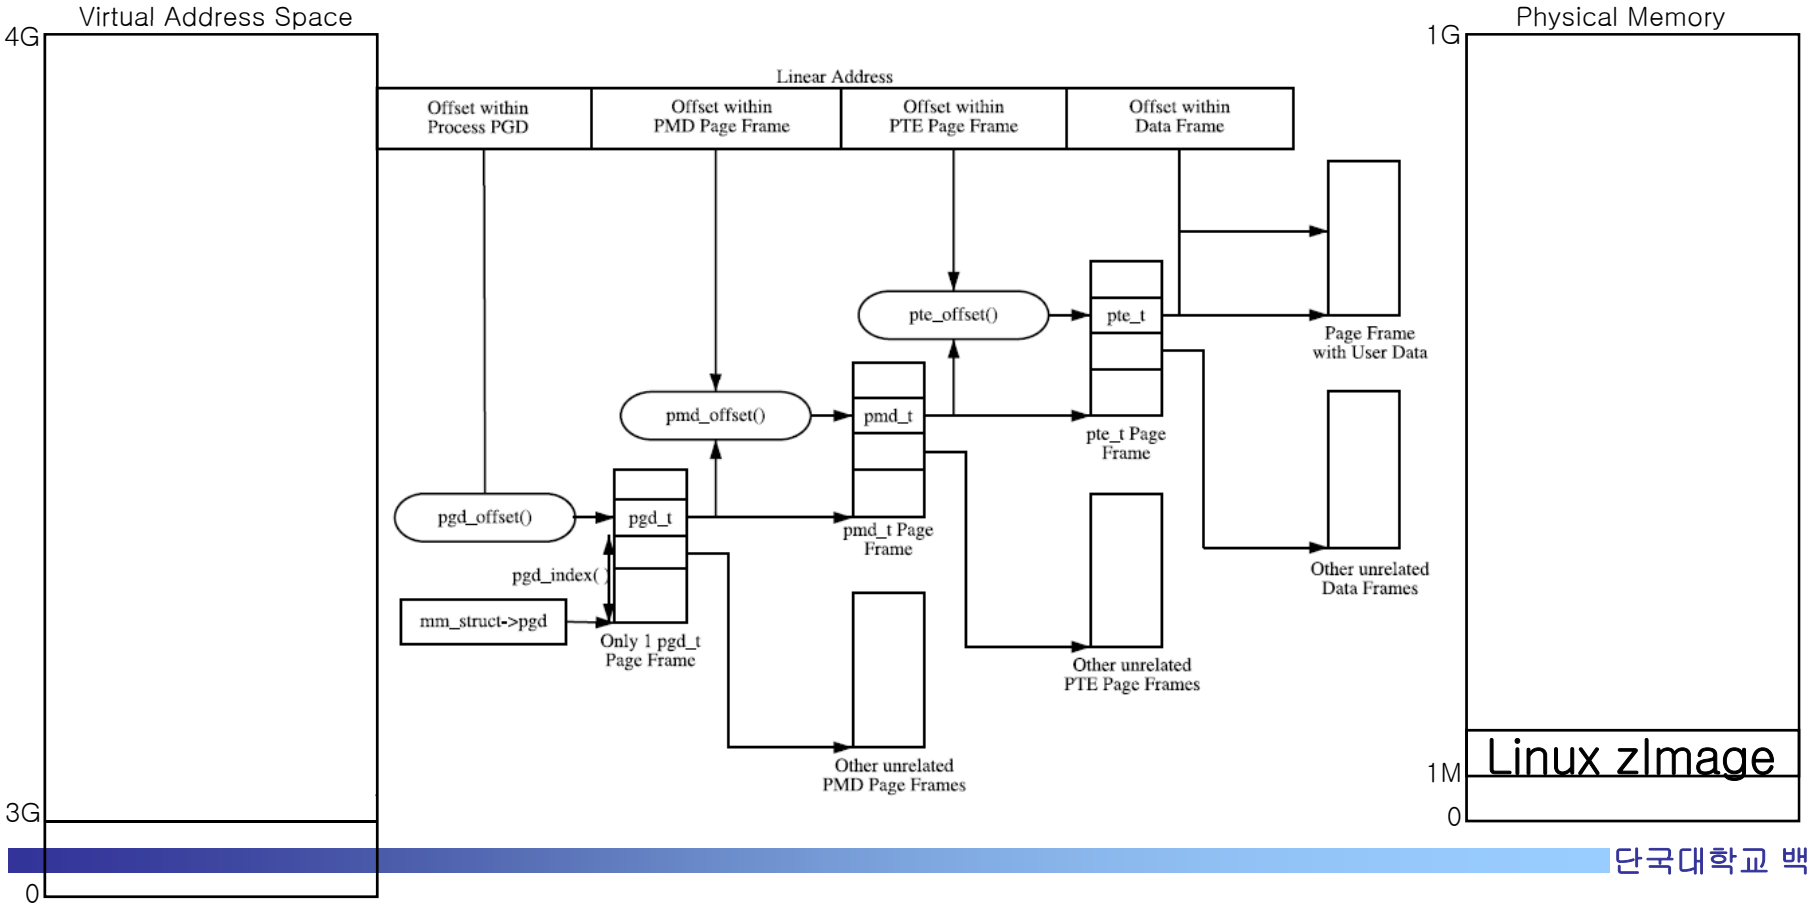

Kernel Address Space(9/13)

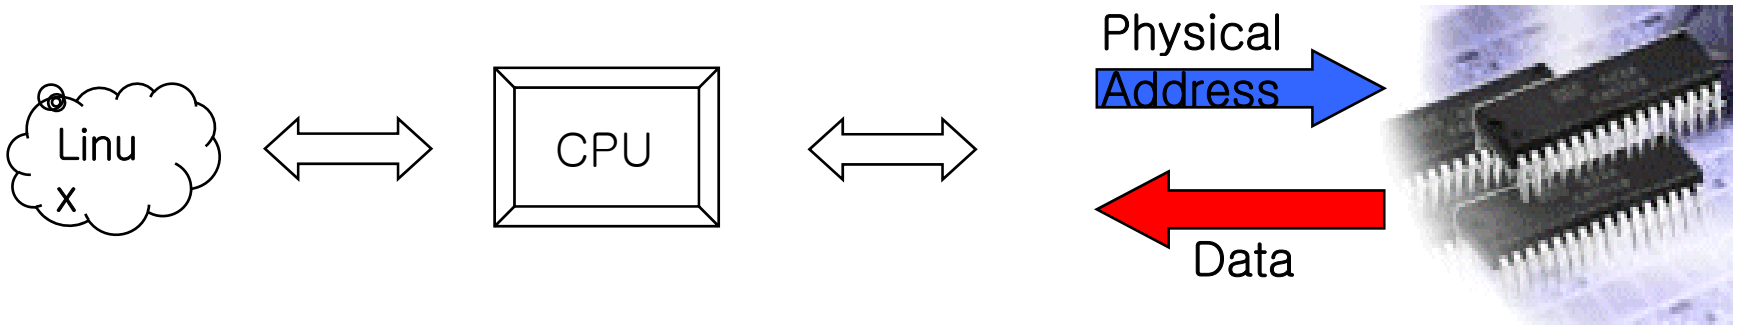

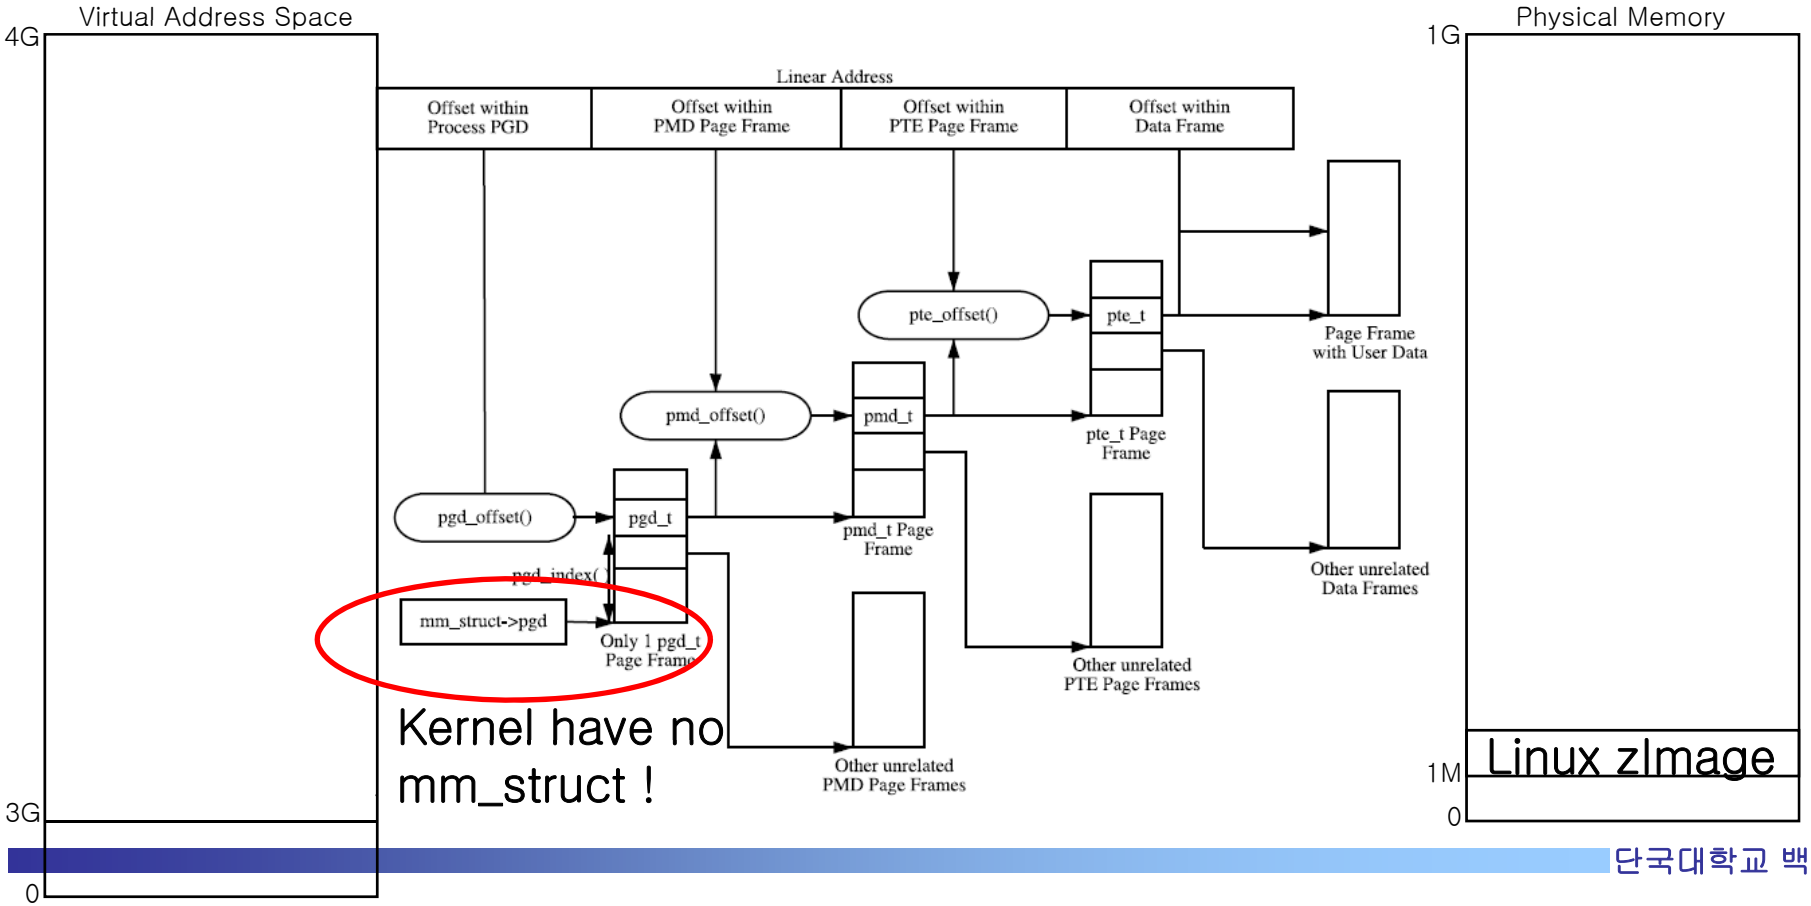

Kernel Address Space(10/13)

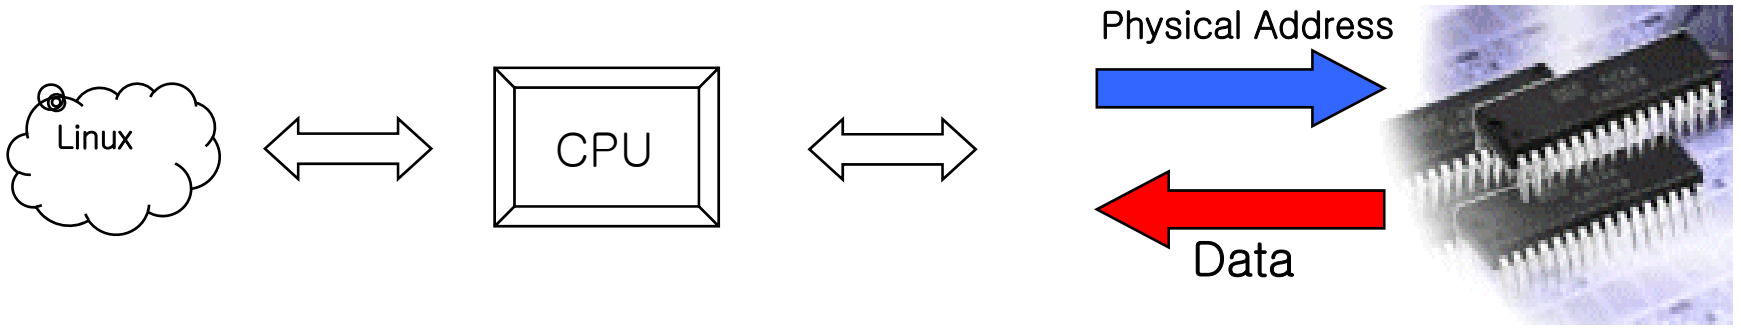

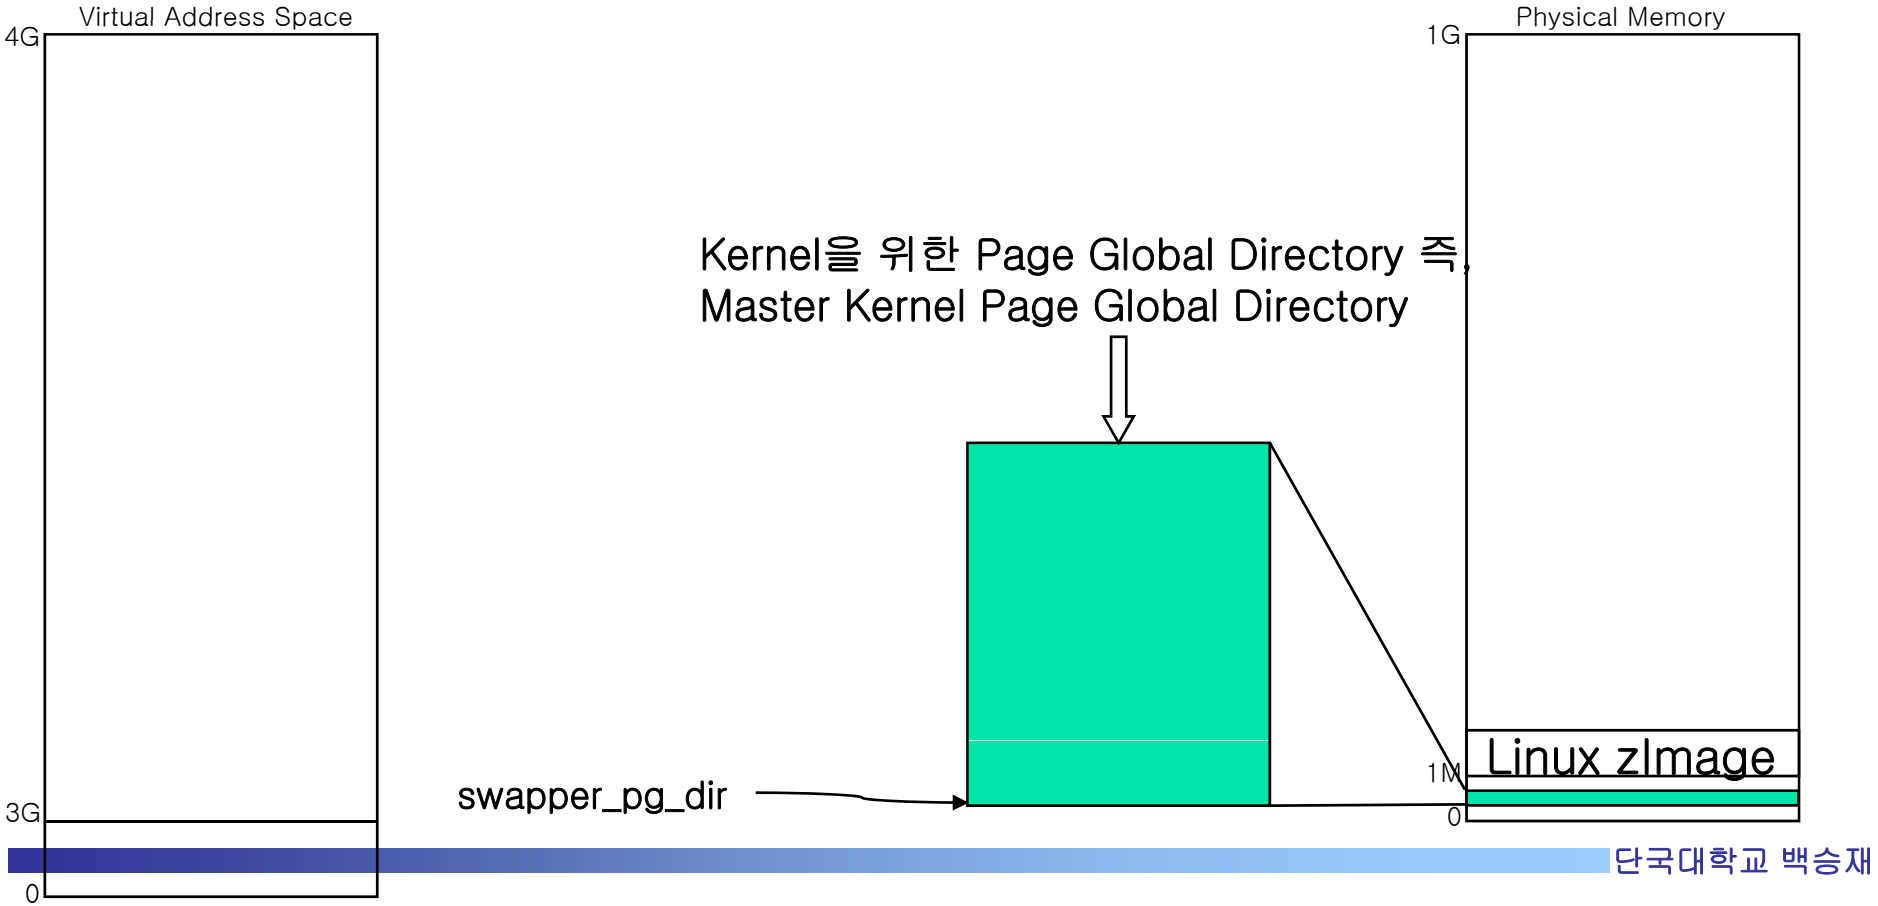

Kernel Address Space(11/13)

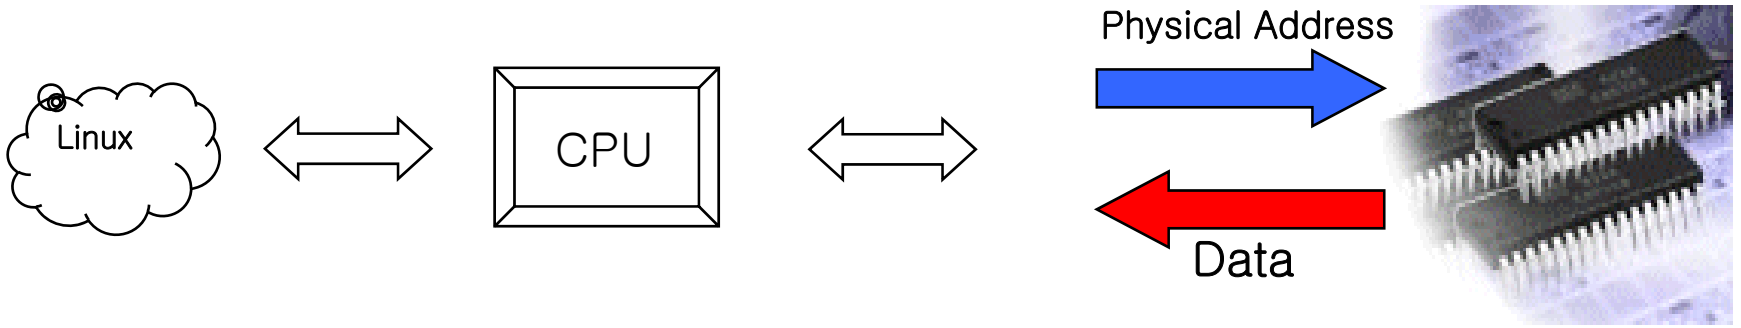

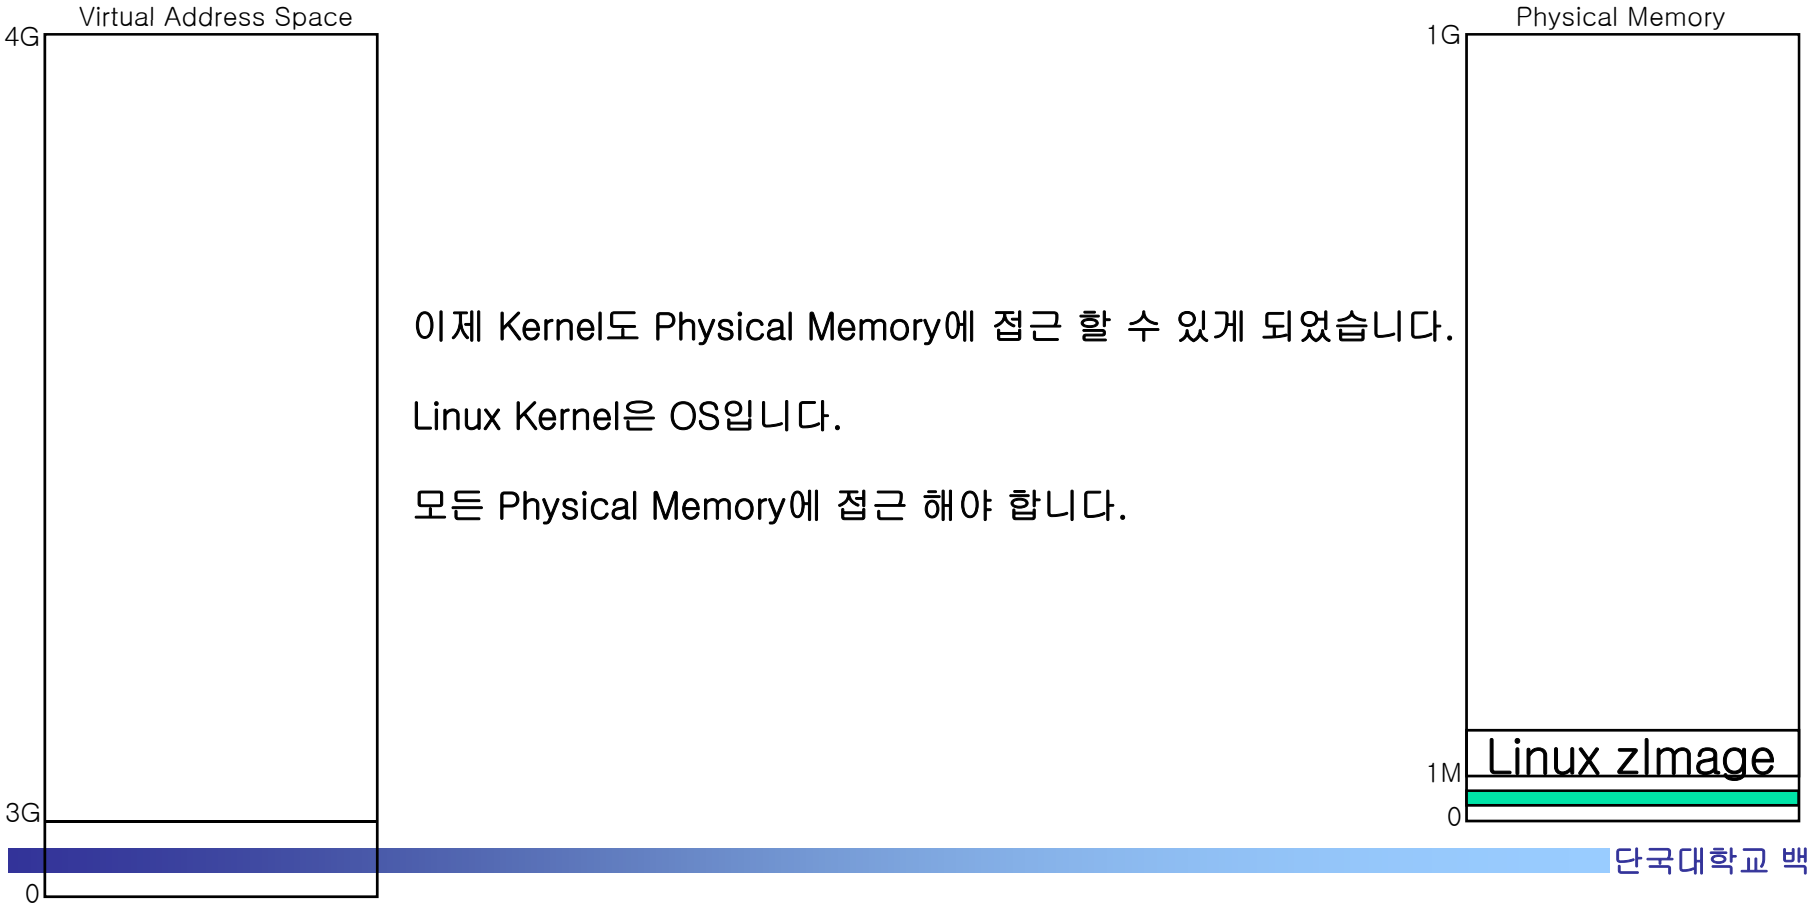

이제 Kernel도 Physical Memory에 접근 할 수 있게 되었습니다.

Linux Kernel은 OS입니다.

모든 Physical Memory에 접근 해야 합니다.

Kernel Address Space(12/13)

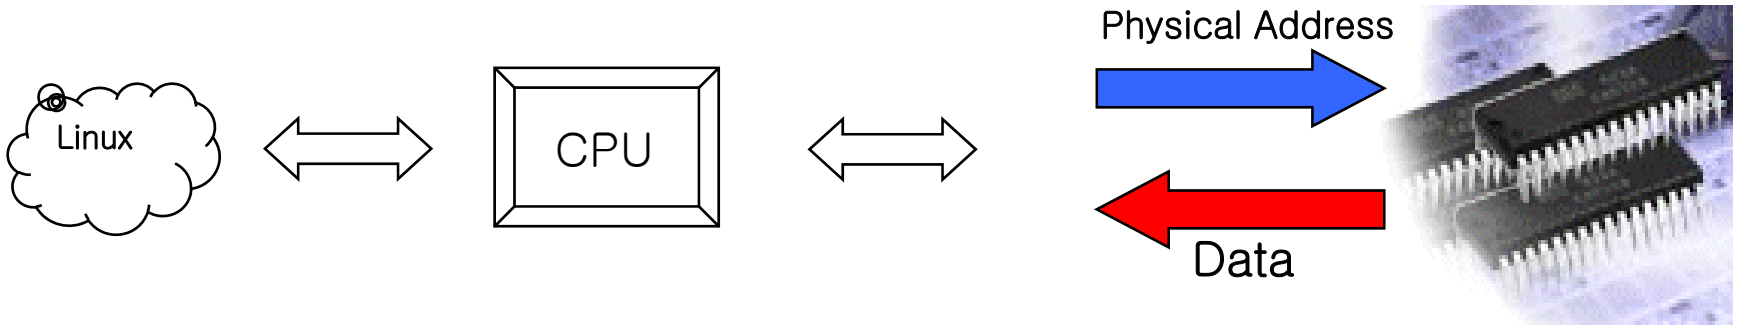

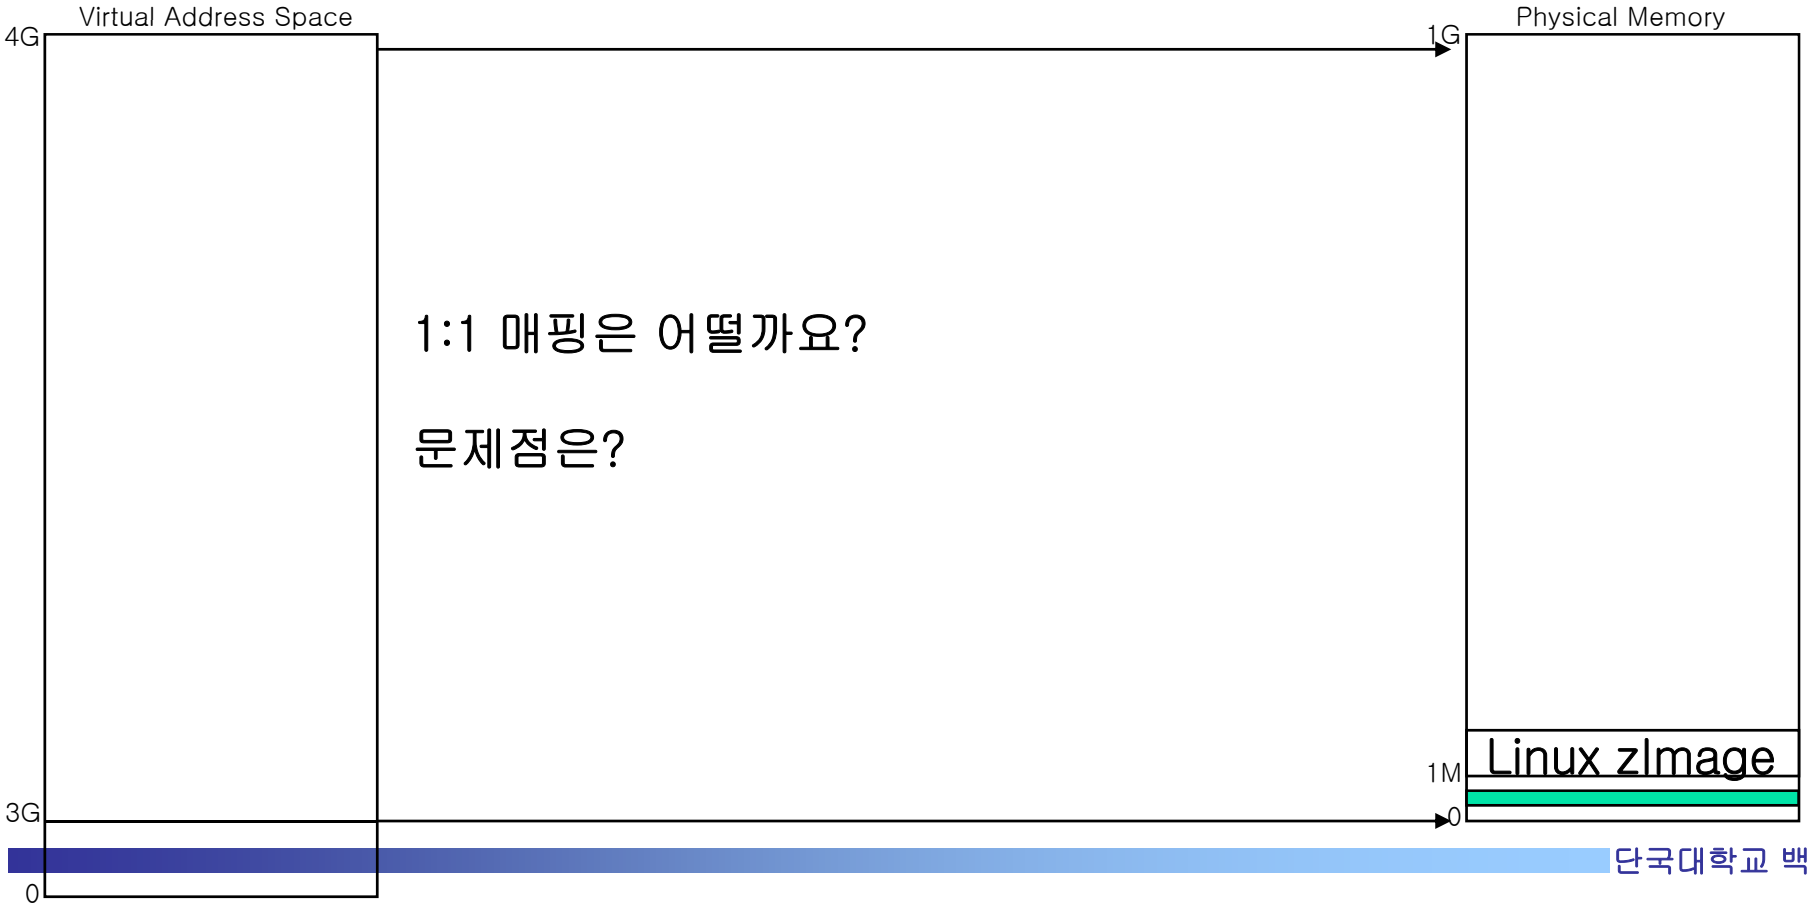

Kernel Address Space(13/13)

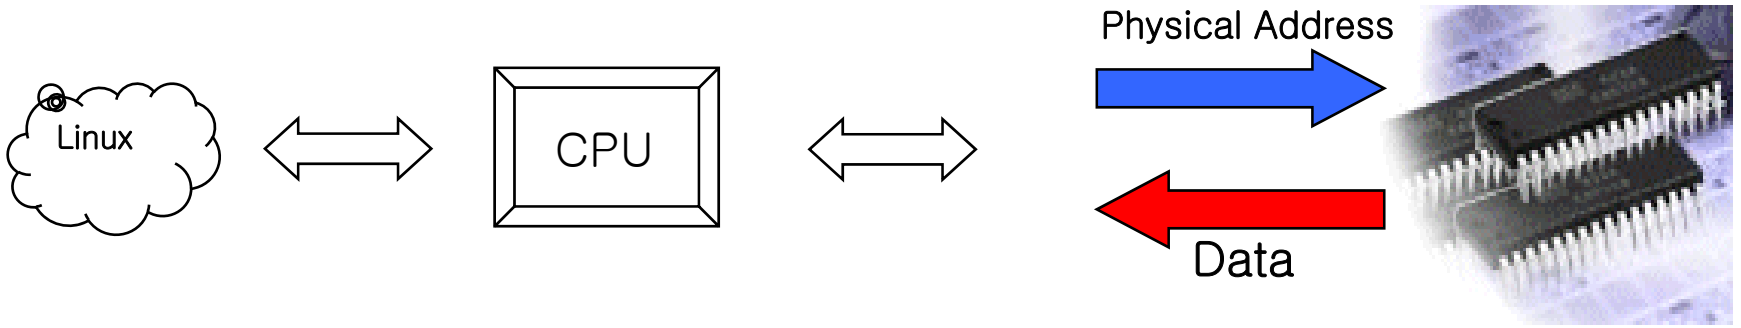

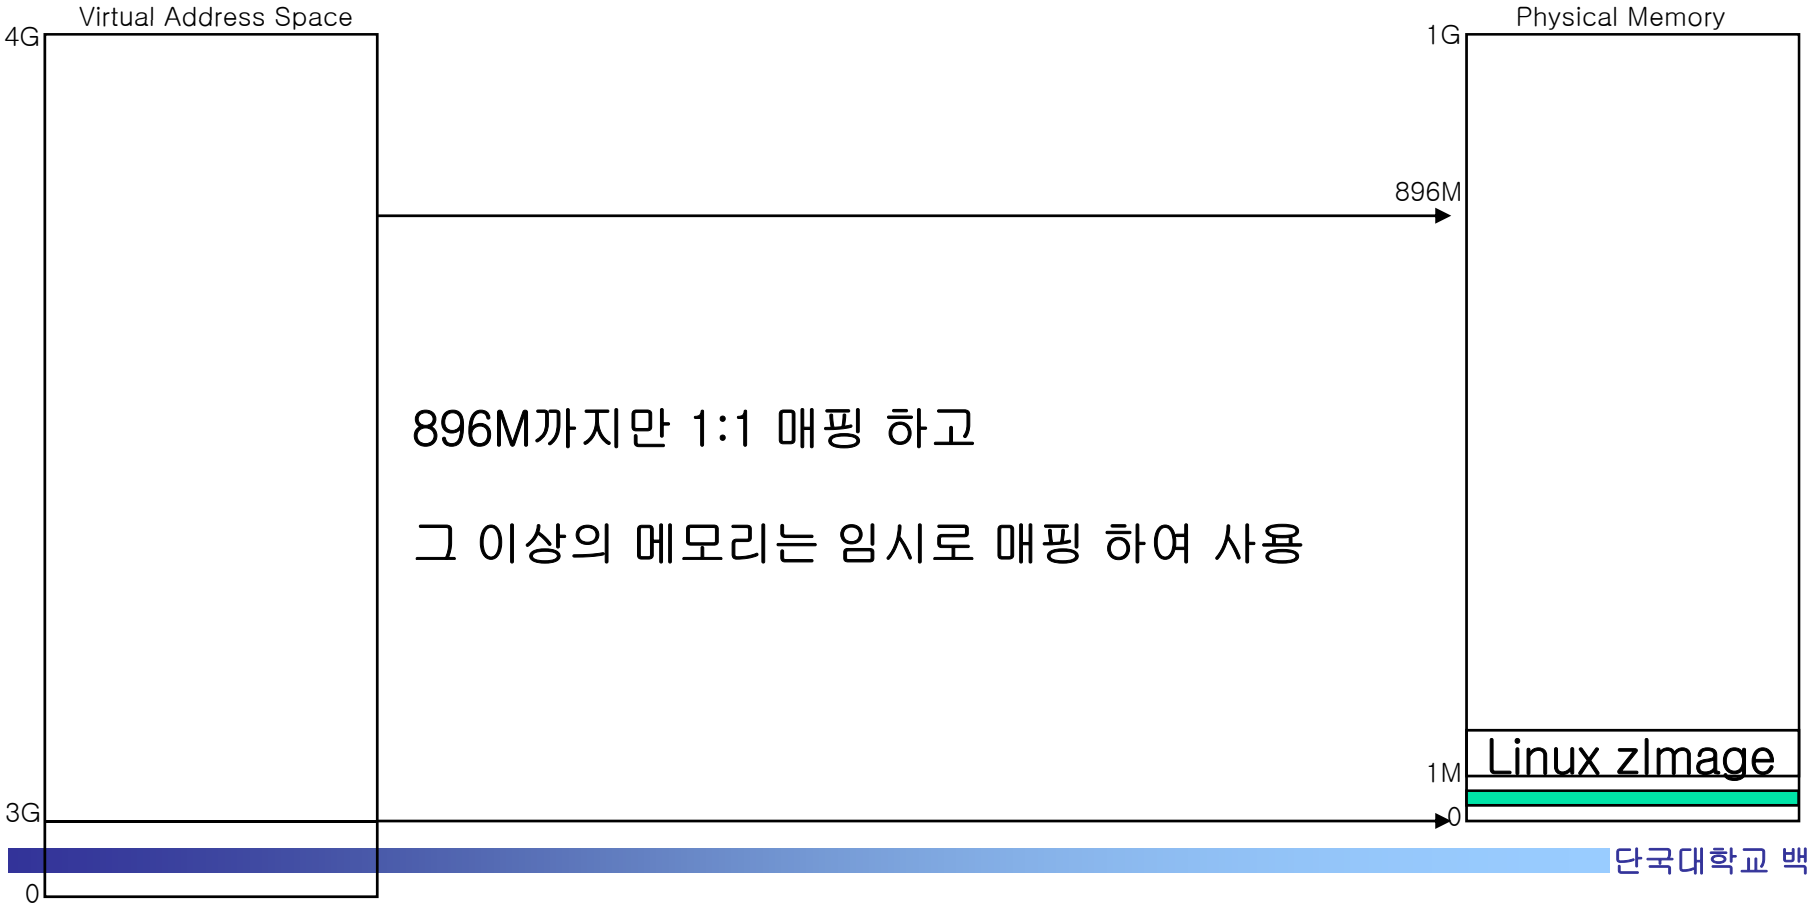

ZONE 자료 구조

```
typedef struct zone_struct{
        spinlock_t      lock;
                        //concurrent 한 접근 으로부터 zone을 보호하는 spinlock
        unsigned long   free_pages;
                        //현재 zone내의 free page들의 총 개수
        unsigned long   pages_min, pages_los, pages_high;
                        //zone watermarks
        int             need_balance;
                        //이 플래그는 zone의 균형을 유지하기 위해 kswapd 에게 pageout요청을 하는데 사용되는 flag이다
        free_area_t     free_area[MAR_ORDER];
                        //buddy allocator이 사용하는 free area bitmaps
        wait_queue_head_t *wait_table;
                        // Process들이 page가 free되기를 기다릴 때 사용되는 wait queues의 hash table이다
                        // 이는 wait_on_page()와 unlock_page()에서 매우 중요하다
                        // 물론 process들은 한 개의 queue에서 대기 할 수도 있지만, 이렇게 하게 된다면
                        // wake up 하게 되는 때에, 모든 process들은 lock걸리기 전까지는 page를 얻기 위해 경쟁하게 된다
                        // 이렇게 공유자원을 얻기 위해 다투는 프로세스들의 큰 그룹을
                        // Thundering herd라고 부른다.
                        // (thundering herd : 여러 프로세스가 깨어나서, 이중, 하나만 사용할 수  있는 자원을 차지하려고 경쟁하고,
                        //                    나머지 프로세스는 다시 잠든 상태로 돌아가는 상황)
        unsigned long   wait_table_size;
                        //hash table내의 queue개수를 결정하는, 2의 제곱의 수
        unsigned long   wait_table_shift;
                        //위에 정의된 table size를 계산하는데 사용되는 이진 비트 조합
        struct pglist_data *zone_pgdat;
                        //부모 pg_data_t를 가리키는 pointer
        struct page     *zone_mem_map;
                        //현재 zone이 참조하게 되는 전역 배열 mem_map내의 첫 번째 page
        unsigned long   zone_start_paddr;
                        //node_start_paddr과 유사하게 사용됨
        unsigned long   zone_start_mapnr;
                        //node_start_mapnr과 유사하게 사용됨
        char            *name;
                        //ZONE을 나타내는 'DMA', 'NORMAL', 'HIGHMEM'중 하나의 문자열
        unsigned long   size;
                        // page단위로 표현되는 zone의 크기
}zone_t;
```

ZONE의 watermarks

- Zone Watermarks

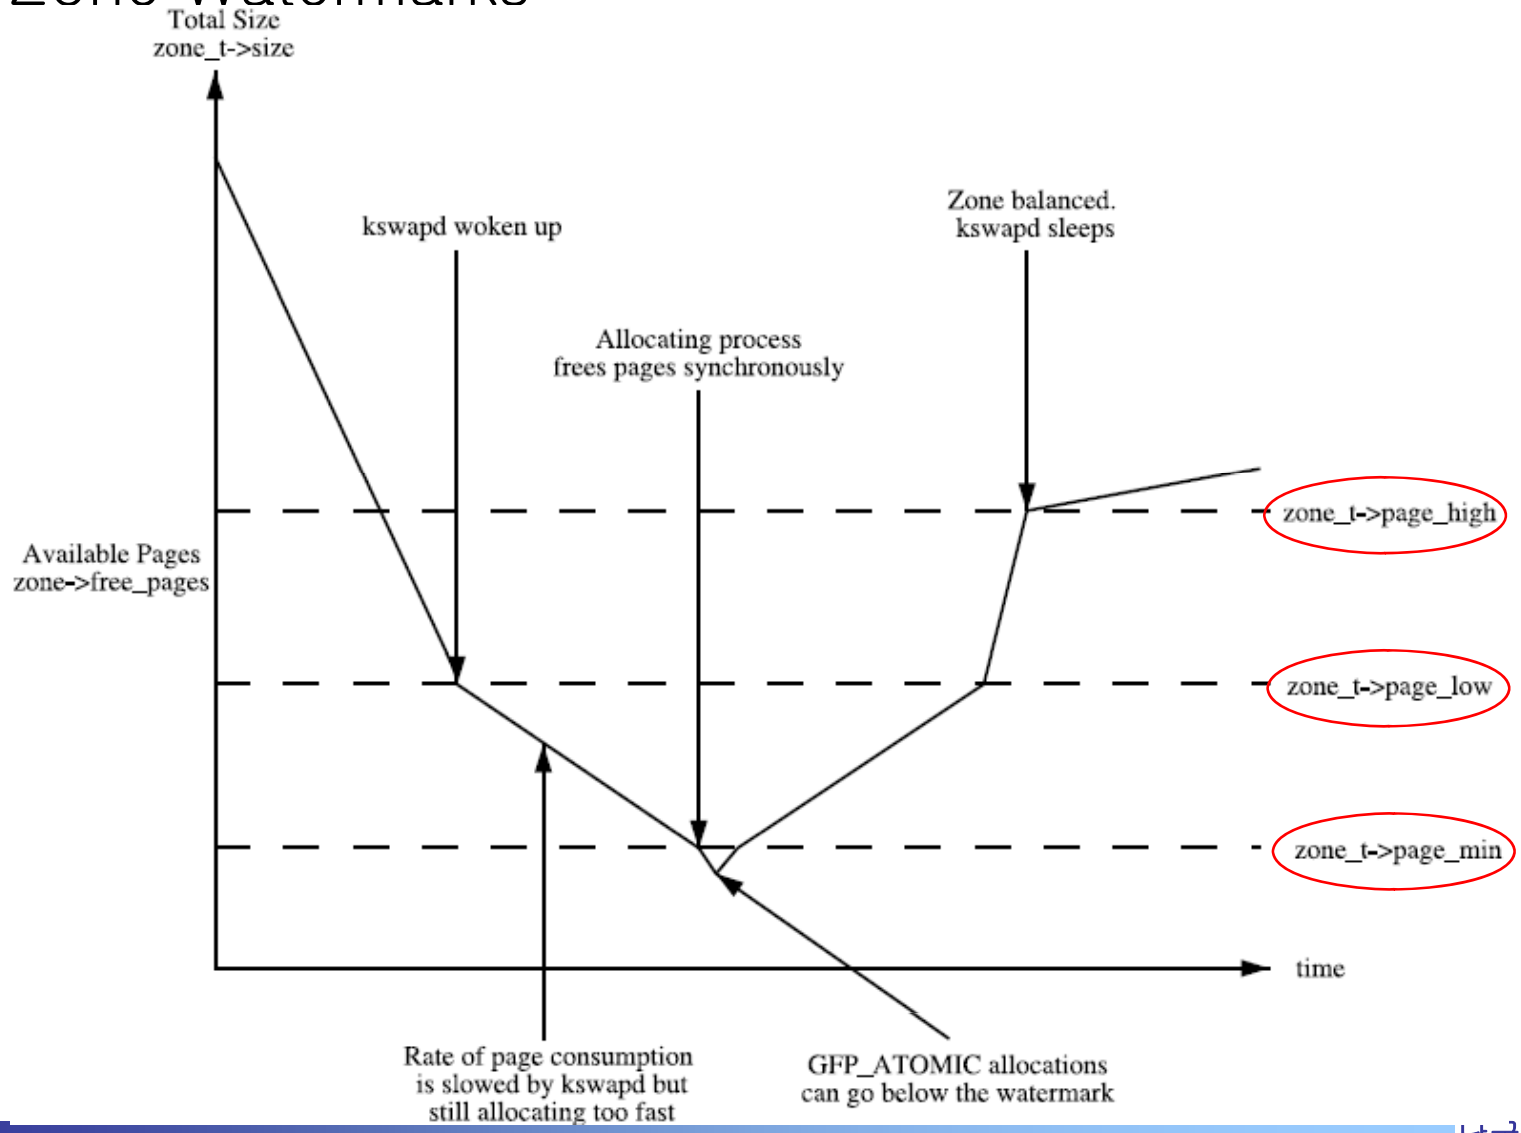

Watermarks 계산

- Zone Watermarks
  - ✓ page_low, pages_min, pages_high
  - ✓ 보통
    - pages_low = pages_min * 2
    - pages_high = pages_min * 3
  - ✓ pages_min 필드는
    - free_area_init_core() 함수 내에서 계산됨
    - 보통 (ZoneSizeInPages / 128)

ZONE과 PageFrame

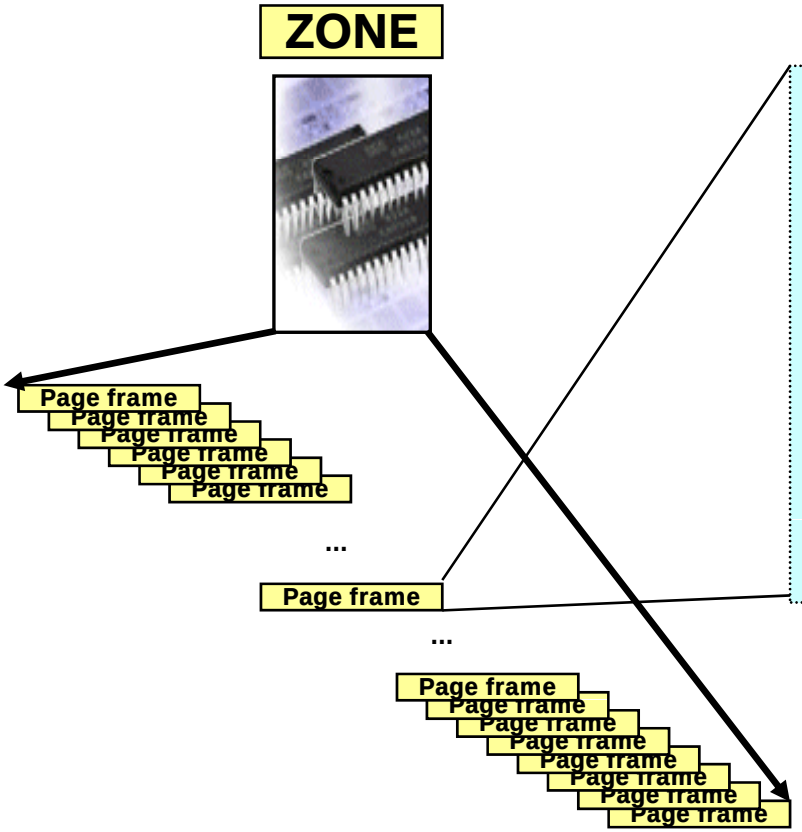


```
typedef struct page {
        struct list_head                list;
        struct address_space  *mapping;
        unsigned long                   index;
        struct page                     *next_hash;
        atomic_t                        count;
        unsigned long                   flags;
        struct list_head                lru;
        struct page                     **pprev_hash;
        struct buffer_head              * buffers;
#if defined(CONFIG_HIGHMEM) || defined(WANT_PAGE_VIRTUAL)
        void                            *virtual;
#endif /* CONFIG_HIGMEM || WANT_PAGE_VIRTUAL */
} mem_map_t;
```

각 NODE의 모든 page 구조체는 보통 ZONE_NORMAL의 시작부분
(혹은 커널이 올라 오기 위해 예약해 놓은 메모리 바로 다음)
위치에 있는 전역 배열인 "**mem_map**"에 유지된다

Page Frame 자료 구조

```
typedef struct page{
    struct list_head list;
        // page는 많은 list에 속해 있을 수 있고, 이 필드는 list head를 위해 사용된다.
        // 예를들어, mapping되어 있는 page는 address_space에 의해 관리되는 세 개의 원형 링크드 리스트 중 하나에 속해 있을 것이다.
        // 이 세개의 원형 링크드 리스트는 clean_pages, dirty_pages, locked_pages이다.
        // slab allocator에서 이필드는 슬랩 할당자에 의해 할당되었을때 page를 관리하기 위해
        // slab이나 cache structures로의 포인터를 저장하는 역할을 한다.
        // 또한 free pages의 link blocks 에서도 사용된다.
    struct address_space *mapping
        // 파일이나 device가 memory mapped되어 있을 때, 그들의 inode는 address_space와 연결되어 있다.
        // 만약 이 page가 파일에 연결되어 있다면 이 필드는 address space를 가리킨다.
        // 만약 page가 anonymous이며 mapping이 set되어 있다면,
        // address_space는 swap address space를 관리하는 swapper_space이다.
    unsigned long index;
        // 이 필드는 두가지 용도를 가지며, 이는 page의 state가 결정한다.
        // 만약 이 page가 file mapping의 일부라면 이는 file내의 offset이다
        // 만약 이 page가 swap cache의 일부라면 이는 swap address space(swapper_space)를 위한 address_space내의 offset이 됨
        // 둘째, 만약 page들의 블록이 특정 process를 위해 free되었다면
        // 블록 내에서의 순서가 저장될 것이다. 이는 __free_pages_ok()함수 내에서 set 된다
     struct page *next_hash;
        // 파일 매핑의 일부인 page는 inode와 offset에 의해 hash된다.
        // 이 필드는 같은 hash bucket을 공유하는 페이지 들을 link시켜주는 필드이다.
```

Page Frame 자료 구조

```
    atomic_t count;
        // page의 참조 횟수이다. 만약 0이 되면 이 페이지는 free될 것이다.
        // 그보다 크다면, 하나 이상의 프로세스에서 사용 중 이거나,
        // I/O를 기다리기 위한 작업등으로 인해 커널 내에서 사용 중임을 나타낸다.
    unsigned long flags;
        // page의 상태를 나타내는 flags이다. 이는 <linux/mm.h>내에 모두 정의 되어 있고, 표 2.1에 나열해 놓았다.
        // bit를 test, clear, set하기 위한 여러 개의 매크로가 정의 되어 있으며, 이를 표 2.2에 보였다.
        // 사실 유일하게 관심 있는 함수는 아키텍쳐에 의존적인 함수인 arch_set_page_uptodate()를 call하는SetPageUptodate()이다.
    struct list_head lru;
        // page 교체 정책을 위해, 교체 되어 나갈 page는
        // page_alloc.c내에 정의 되어 있는 active_list나 inactive_list 둘 중 하나에 존재해야 한다.
        // 이 필드는 이러한 LRU리스트의 list head를 가리키게 된다.
    struct page **pprev_hash;
        // next_hash의 보완책인 이 필드로 인해 hash는 doubly lonked list로 동작할 수 있다.
    struct buffer_head *buffers;
        // 만약 page가 연결되어 있는 block device를 위한 buffer를 가지고 있다면
        // buffer_head에 대한 정보를 유지하기 위해 사용된다.
        // 만약 (it is backed by a swap file)이면 프로세스에 의해 mapped된 anonymous page인 경우엔
        // 연결되어 있는 buffer_head 를 가리킬 수도 있다.
        // 이때 page는, 속해있는 파일시스템에서 정하는 block size단위로,
        // 저장장치로 저장되는 sync작업이 일어나야 하므로 필요하다.
#if defined (CONFIG_HIGHMEM) || defined(WAANT_PAGE_VIRTUAL)
    void *virtual;
        // 일반적으로는 ZONE_NORMAL에 속해있는 page만이 커널에 의해 직접 지정이 가능하다
        // ZONE_HIGHMEM zone내에 있는 page를 주소지정 하기 위해 kmap()함수가 사용되며
        // 이 함수는 page를 kernel과 map시켜주는 역할을 한다.(9장에서 논의됨)
        // 고정된 개수의 page만이 map 될 수 있다. 만약 page가 map 되었다면, 이 필드는 page의 가상주소를 나타낸다.
#endif /*CONFIG_HIGHMEM || WANT_PAGE_VIRTUAL */
}mem_map_t;
```

Buddy

- To reduce “external fragmentation”
- Fast allocation and de-allocation of pages
- 연속적인 page(block) 단위 별로 관리
  - ✓ 1, 2, 4, 8.. pages → each one block

free_area_t 구조체

```
/* ~/include/linux/mmzone.h
#define     MAX_ORDER        10

typedef struct zone_struct {
        ...
        free_area_t         free_area[MAX_ORDER];
        ...
} zone_t;

typedef struct free_area_struct {
                struct list_head                free_list;
                unsigned long                   *map;
}free_area_t;
```

Data structure

- free_area.[order].free_list
  - ✓ 특정 크기의 free page block들의 이중 연결 리스트
- free_area.[order].map
  - ✓ ((number of pages) -1) >> (order + 4)) + 1bytes
  - ✓ 한 비트가 하나의 버디의 상태를 나타낸다

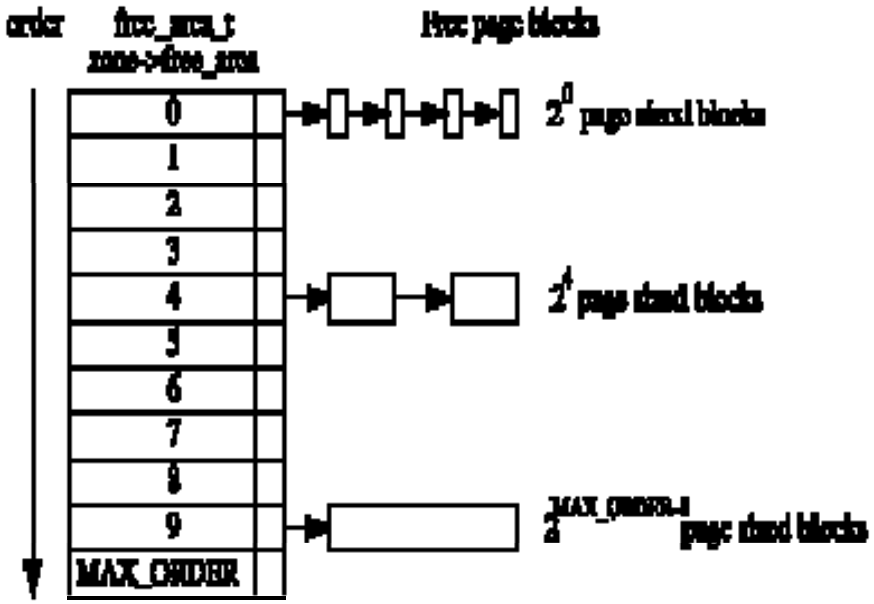

Memory allocation

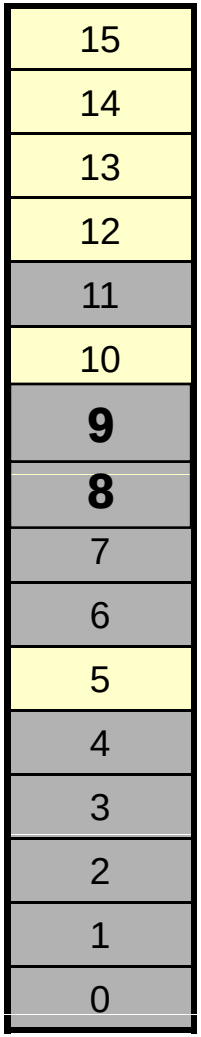

Physical Memory

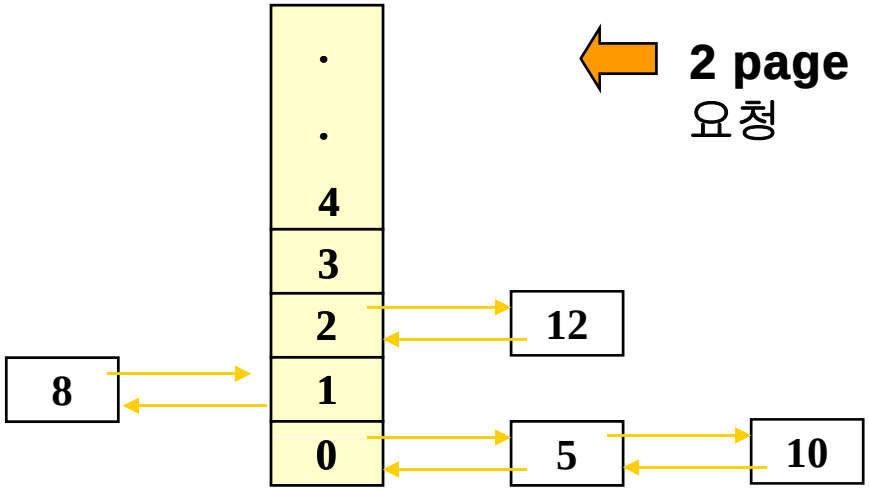

free_area.free_list

2 page 요청

alloc

free

free_area[order].map

Pages	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
order(0)	0		0		1		0		0		1		0		0	
order(1)	0				0				1-> 0				0			
order(2)	0								1							
order(3)	0															

Memory allocation

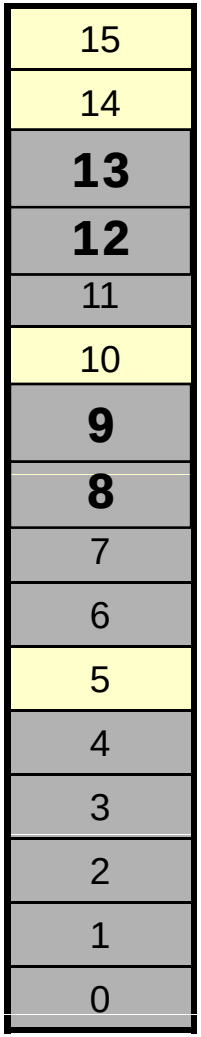

Physical Memory

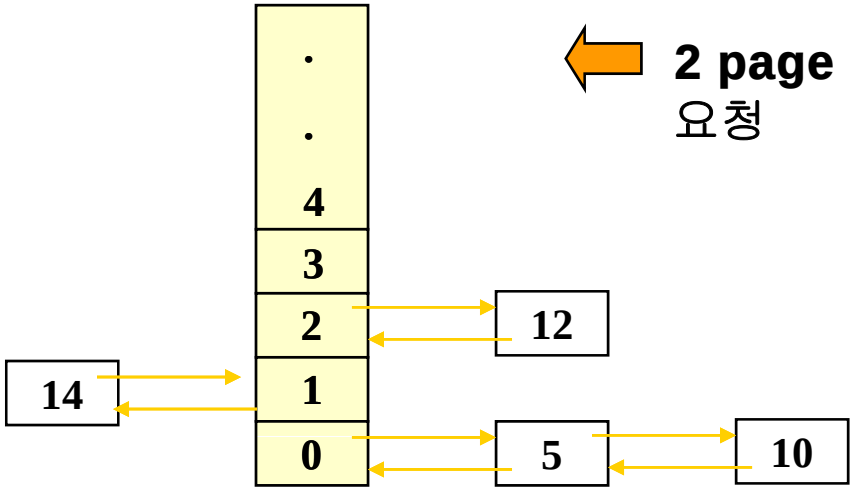

free_area[order].map

Pages	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
order(0)	0		0		1		0		0		1		0		0	
order(1)	0				0				0				0 **-> 1**			
order(2)	0								1 **-> 0**							
order(3)	0															

Memory de-allocation

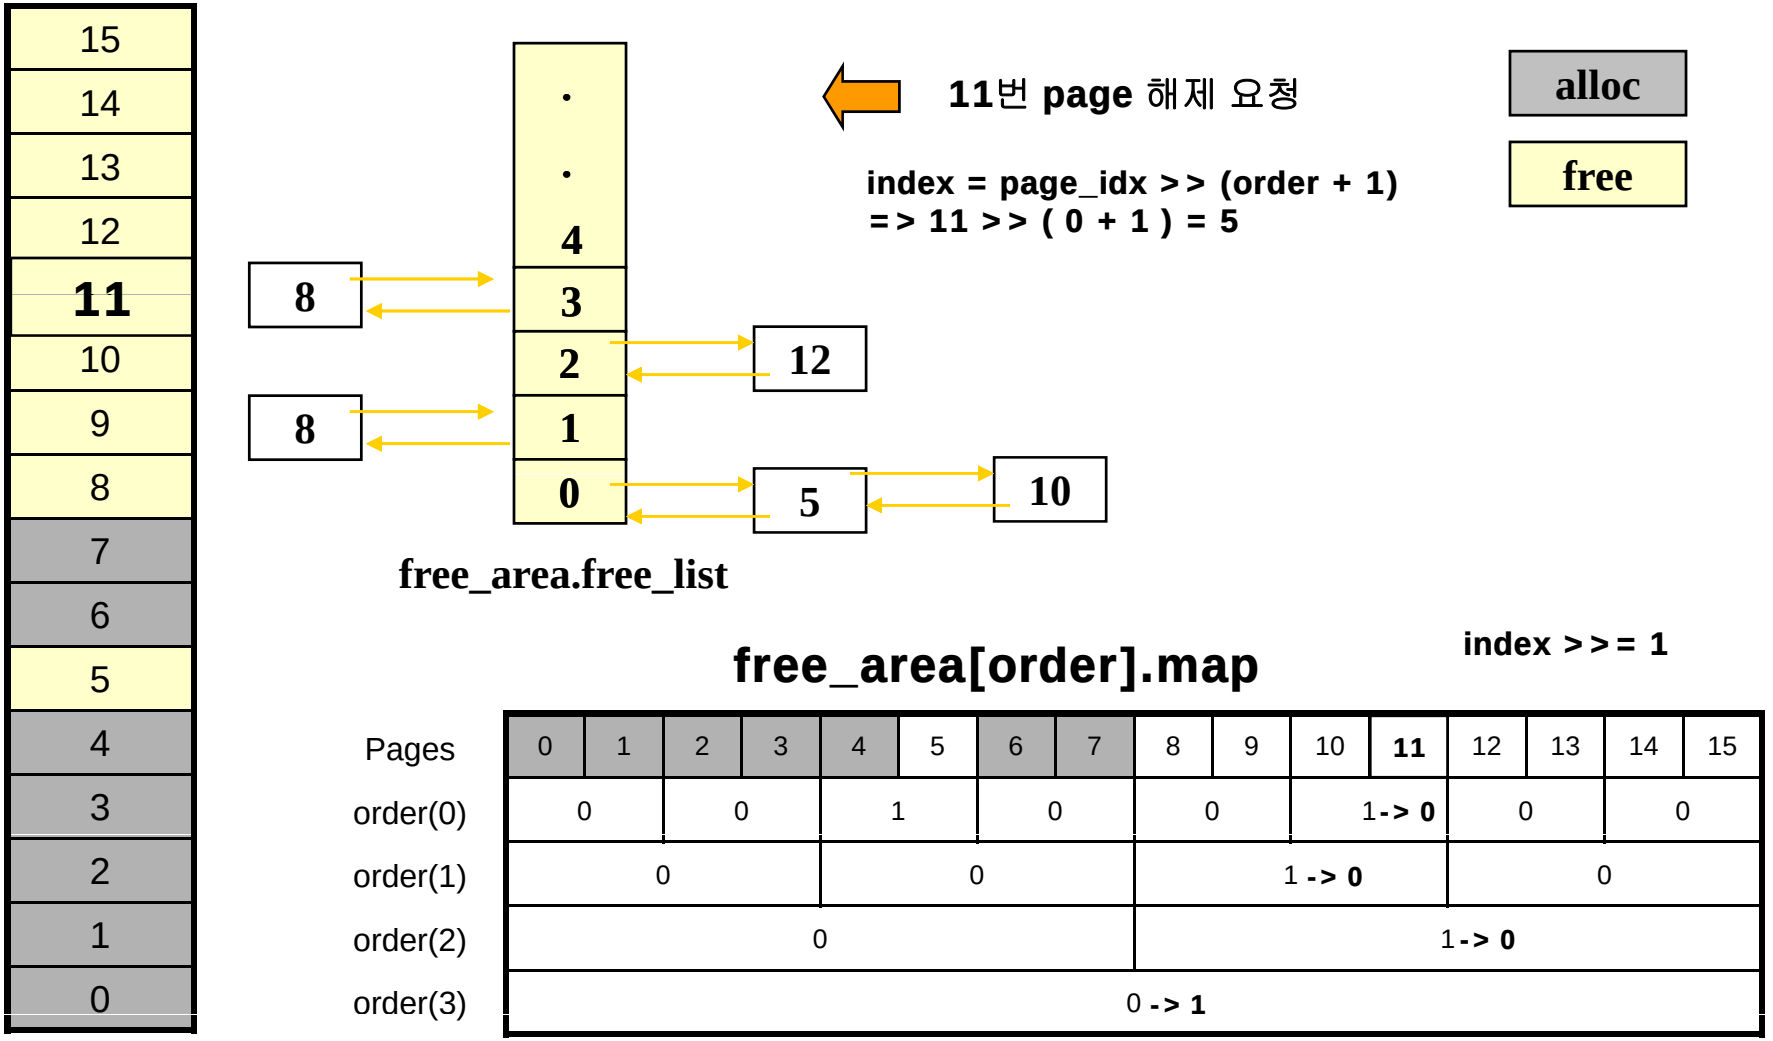

Buddy 관련 함수

`struct page * alloc_page(unsigned int gfp_mask)` Allocates a single page and returns a struct address.
`struct page * alloc_pages(unsigned int gfp_mask, unsigned int order)` Allocates 2^{order} number of pages and returns a struct page.
`unsigned long get_free_page(unsigned int gfp_mask)` Allocates a single page, zeros it, and returns a virtual address.
`unsigned long __get_free_page(unsigned int gfp_mask)` Allocates a single page and returns a virtual address.
`unsigned long __get_free_pages(unsigned int gfp_mask, unsigned int order)` Allocates 2^{order} number of pages and returns a virtual address.
`struct page * __get_dma_pages(unsigned int gfp_mask, unsigned int order)` Allocates 2^{order} number of pages from the DMA zone and returns a struct page.

Table 6.1. Physical Pages Allocation API

`void __free_pages(struct page *page, unsigned int order)` Frees an order number of pages from the given page.
`void __free_page(struct page *page)` Frees a single page.
`void free_page(void *addr)` Frees a page from the given virtual address.

Table 6.2. Physical Pages Free API

Slab Allocator

- 슬랩 할당자
  - ✓ 버디알고리즘은 적은 메모리 할당엔 부적절
  - ✓ 같은 크기의 메모리 공간에 대한 할당을 반복하는 경향 있으므로 캐시 개념 도입

  - ✓ 캐시 : 객체의 모음 ➔ 같은 크기 메모리 공간의 창고
  - ✓ 슬랩 : 캐시가 들어있는 주 메모리 영역을 나눈것(/proc/slabinfo)
    - 연속된 PF하나이상으로 구성됨
    - 할당한 객체와 여유객체를 모두 포함
    - 빈 슬랩의 PF스스로 해제 안함

Slab Allocator 구조

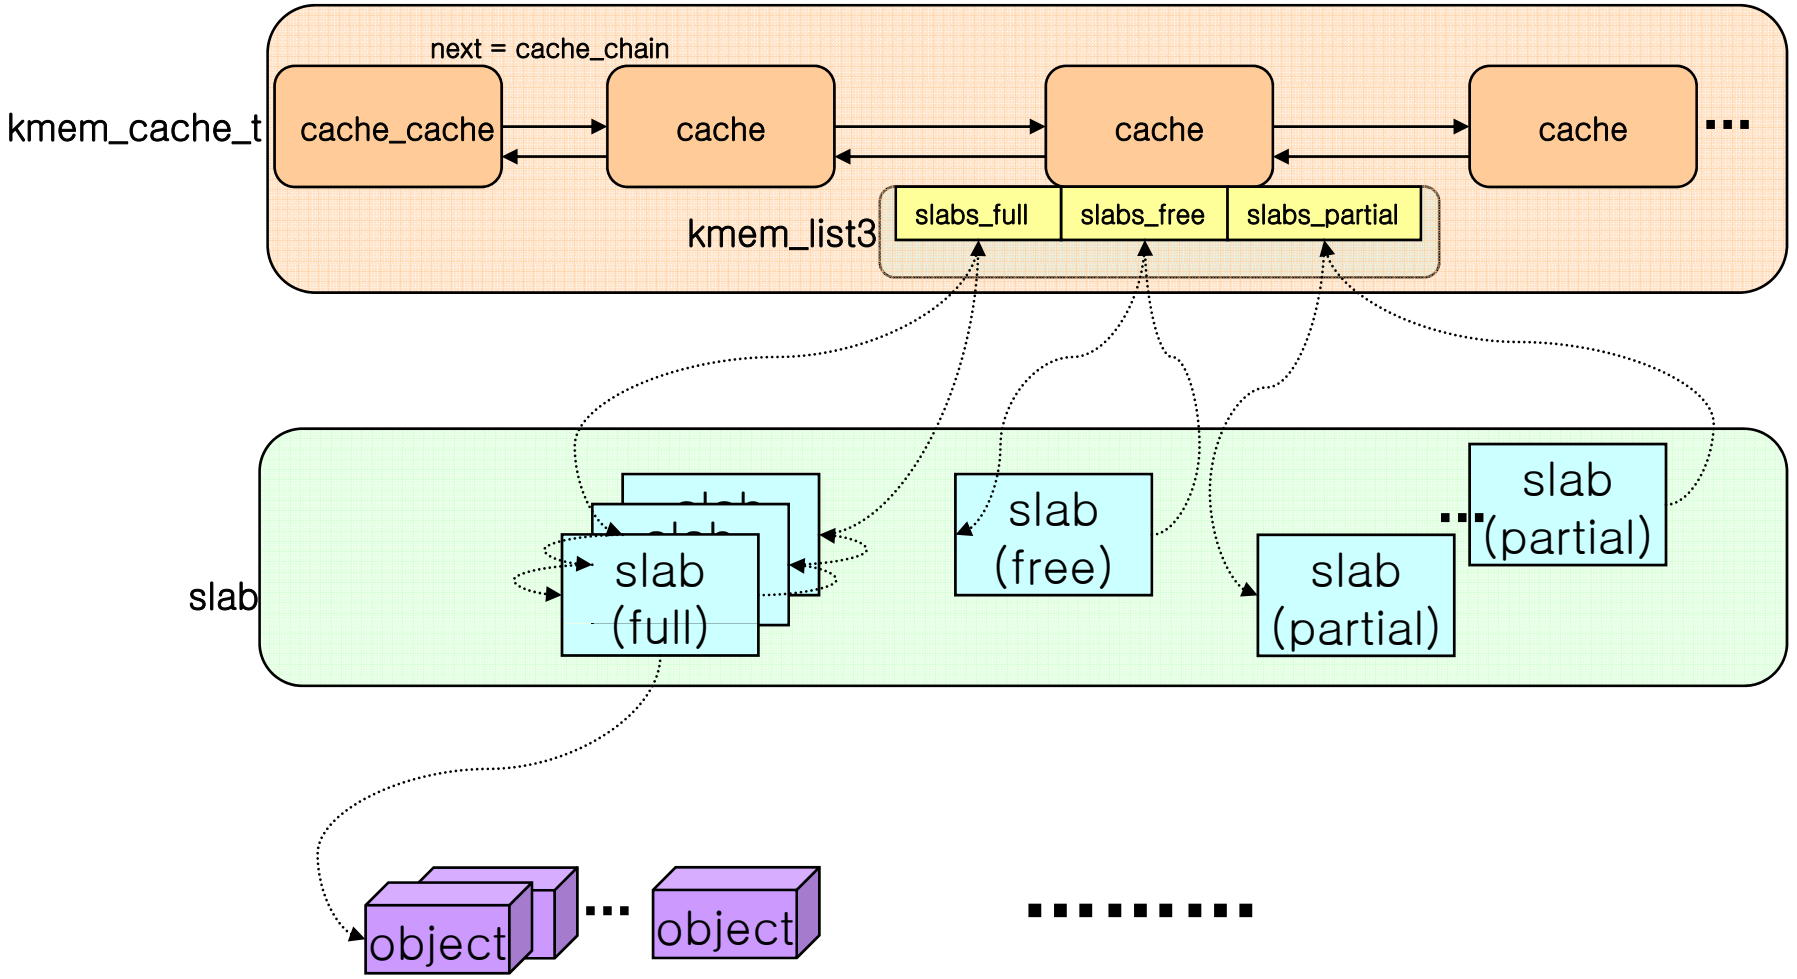

일반 캐시와 특수 캐시

- 일반 캐시
  - ✓ **첫번째 캐시** : 커널이 사용하는 나머지 일반 캐시에 대한 캐시 디스크립터
    - cache_cache변수에 이 디스크립터가 들어있다
  - ✓ **추가 캐시 26개(나머지 26개)** : 기하학적으로 메모리 영역이 들어있다.
    - 32, 64, 128, 256, 512, 1024, 2048, 4096, 8192, 16384, 32768, 65536, 130172바이트 메모리 영역당 **두 개의** 캐시 디스크립터
    - **두 개중 하나는 ISA DMA용, 다른 하나는 일반 할당용**
- 특수 캐시
  - ✓ 자주 할당 해제 되는 커널의 자료구조들을 위한 캐시

슬랩 관련 함수

`kmem_cache_t * kmem_cache_create(const char *name, size_t size, size_t offset, unsigned long flags, void (*ctor)(void*, kmem_cache_t *, unsigned long), void (*dtor)(void*, kmem_cache_t *, unsigned long))`
Creates a new cache and adds it to the cache chain.

`int kmem_cache_reap(int gfp_mask)`
Scans at most `REAP_SCANLEN` caches and selects one for reaping all per-cpu objects and free slabs from. It is called when memory is tight.

`int kmem_cache_shrink(kmem_cache_t *cachep)`
This function will delete all per-cpu objects associated with a cache and delete all slabs in the `slabs_free` list. It returns the number of pages freed.

`void * kmem_cache_alloc(kmem_cache_t *cachep, int flags)`
Allocates a single object from the cache and returns it to the caller.

`void kmem_cache_free(kmem_cache_t *cachep, void *objp)`
Frees an object and returns it to the cache.

`void * kmalloc(size_t size, int flags)`
Allocates a block of memory from one of the sizes cache.

`void kfree(const void *objp)`
Frees a block of memory allocated with kmalloc.

`int kmem_cache_destroy(kmem_cache_t * cachep)`
Destroys all objects in all slabs and frees up all associated memory before removing the cache from the chain.

Table 8.1. Slab Allocator API for Caches

가상 주소 공간 할당/해제

- 일부 가상 주소 공간 = region = 영역 = 구간 = vm_area_struct
- 메모리 구역 겹치는 일은 없음
- 인접한 두 구역은 접근 권한 일치 시 합침

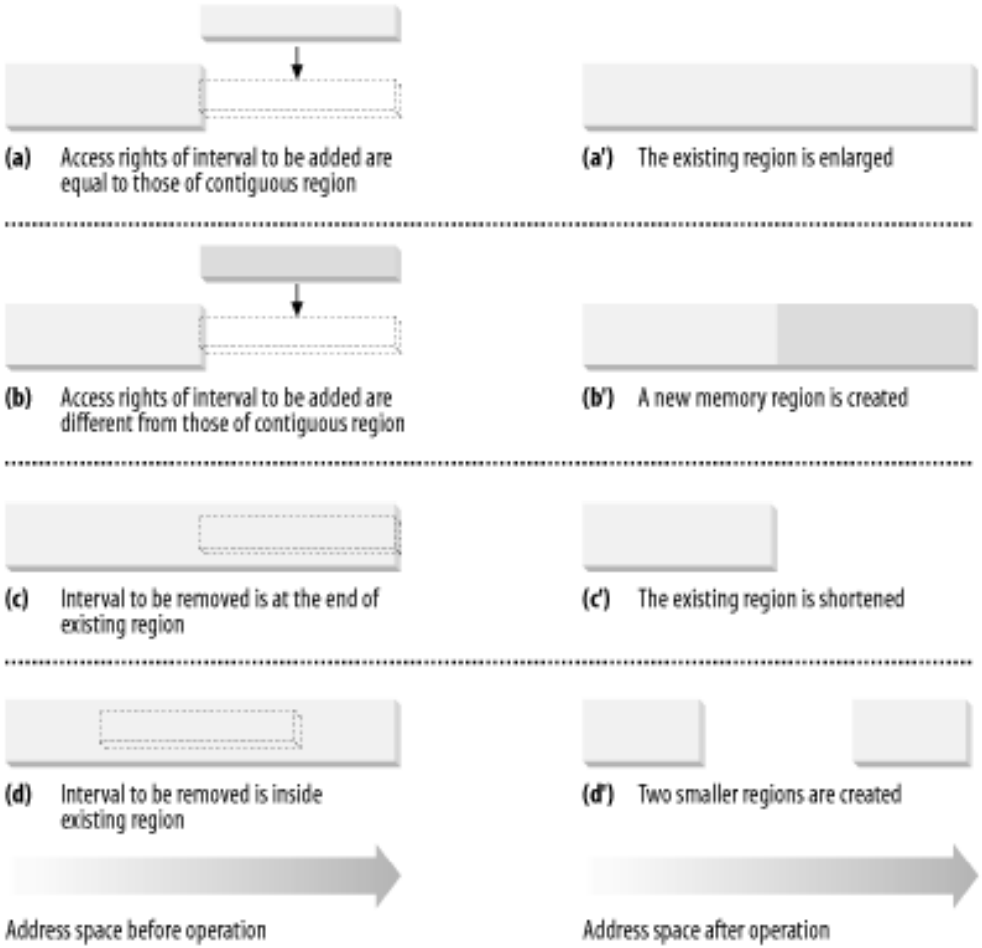

Creating a memory region ex.

- case 1
  - ✓ arch_get_unmapped_area
  - ✓ if addr != null
  - ✓ if addr + len < vma->start

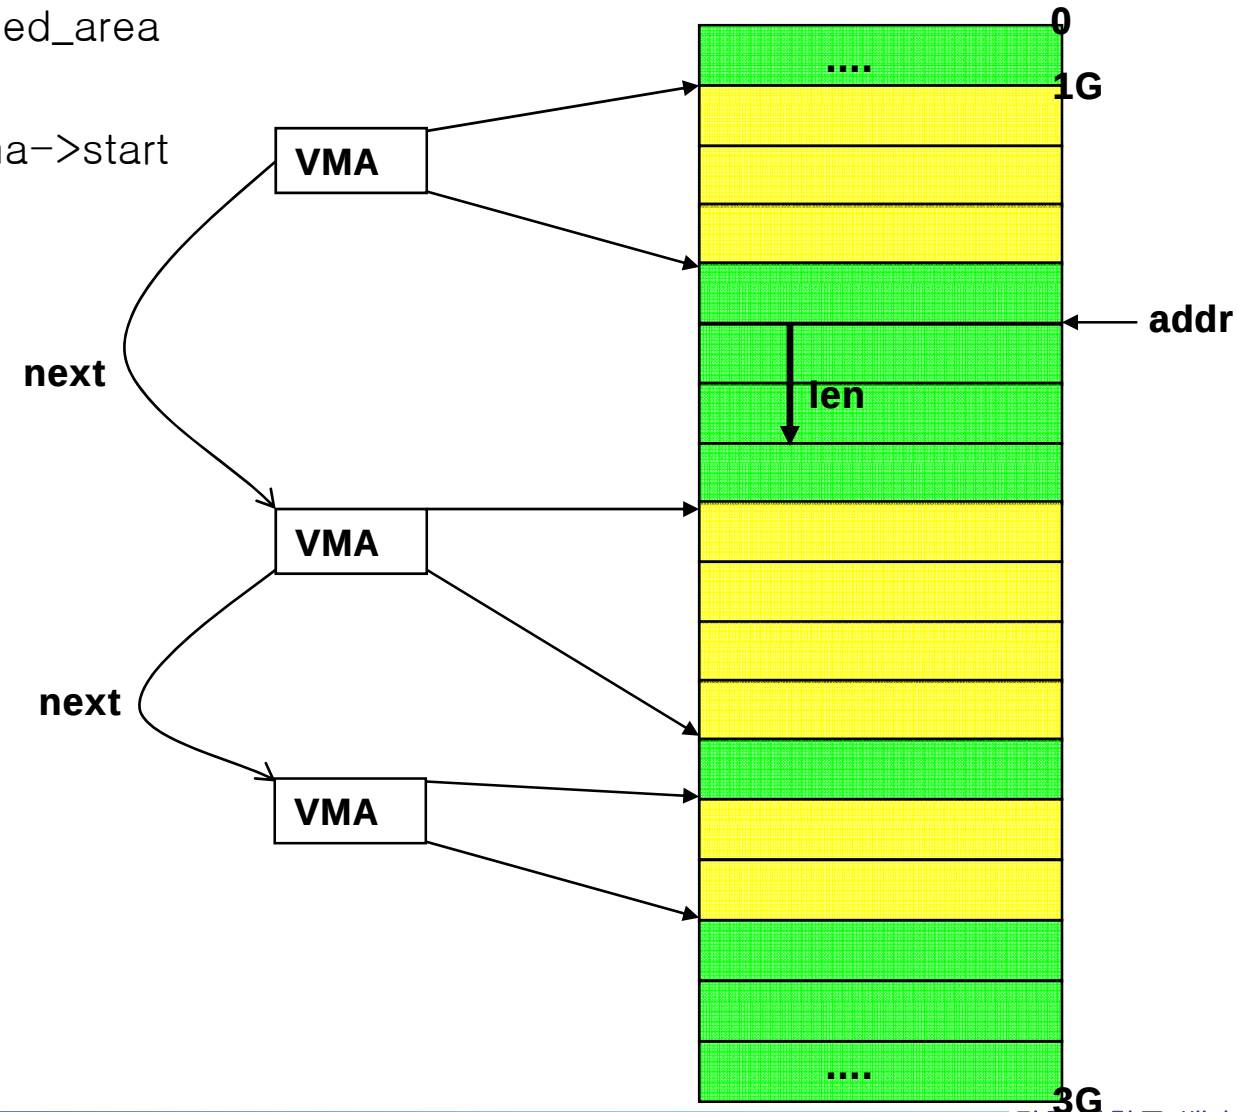

Creating a memory region ex.

- case 2
  - ✓ addr != null
  - ✓ addr + len > vma->start
  - ✓ OR addr == null

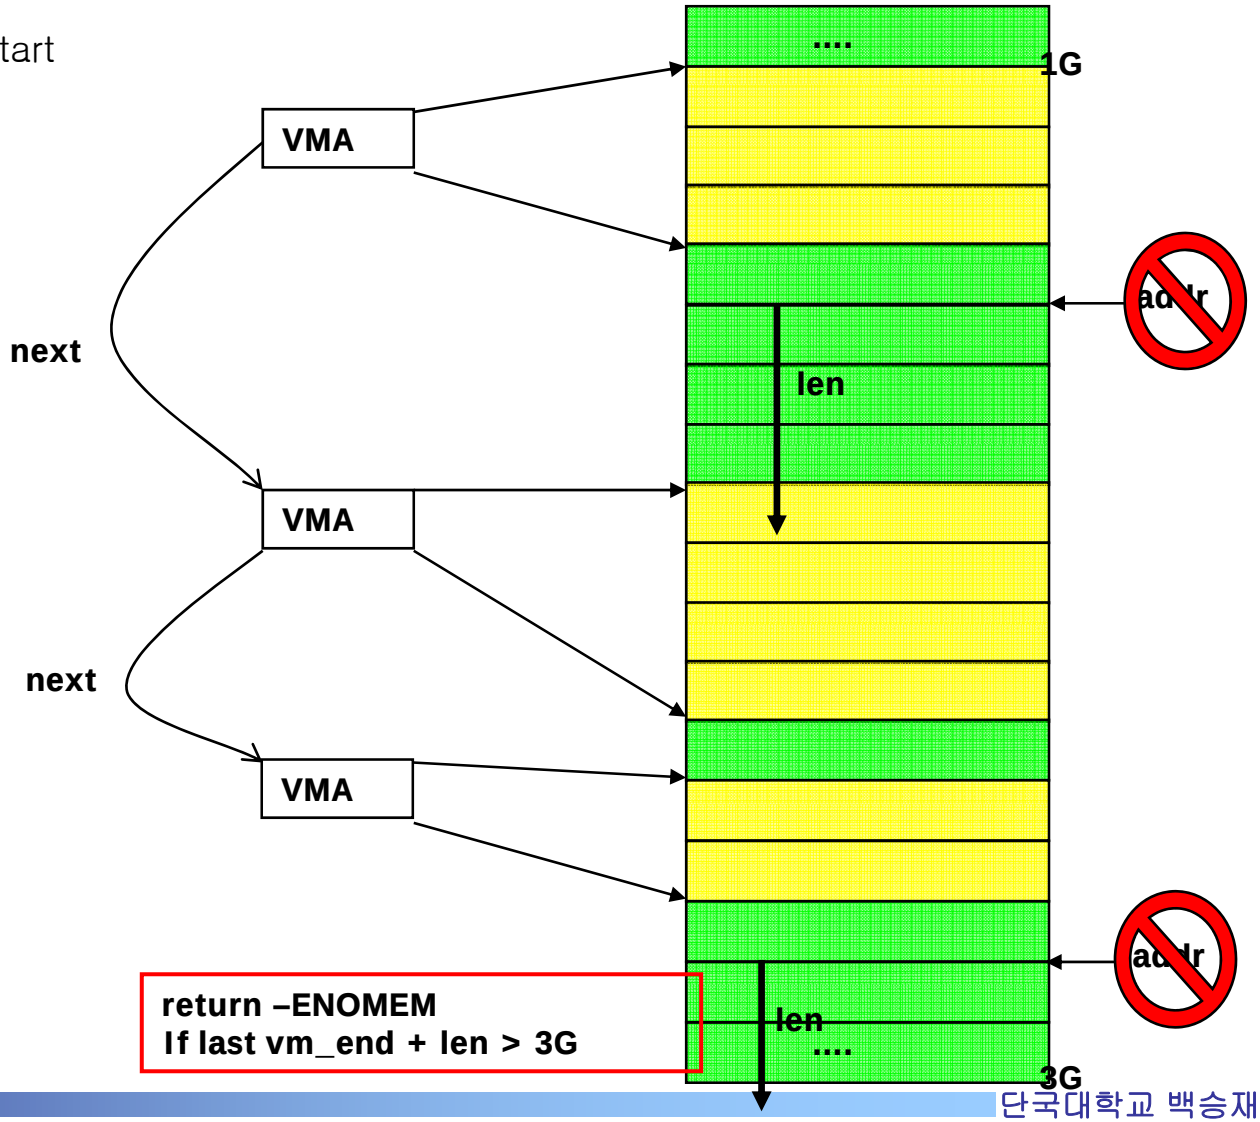

Creating a memory region ex.

- do_mmap_pgoff

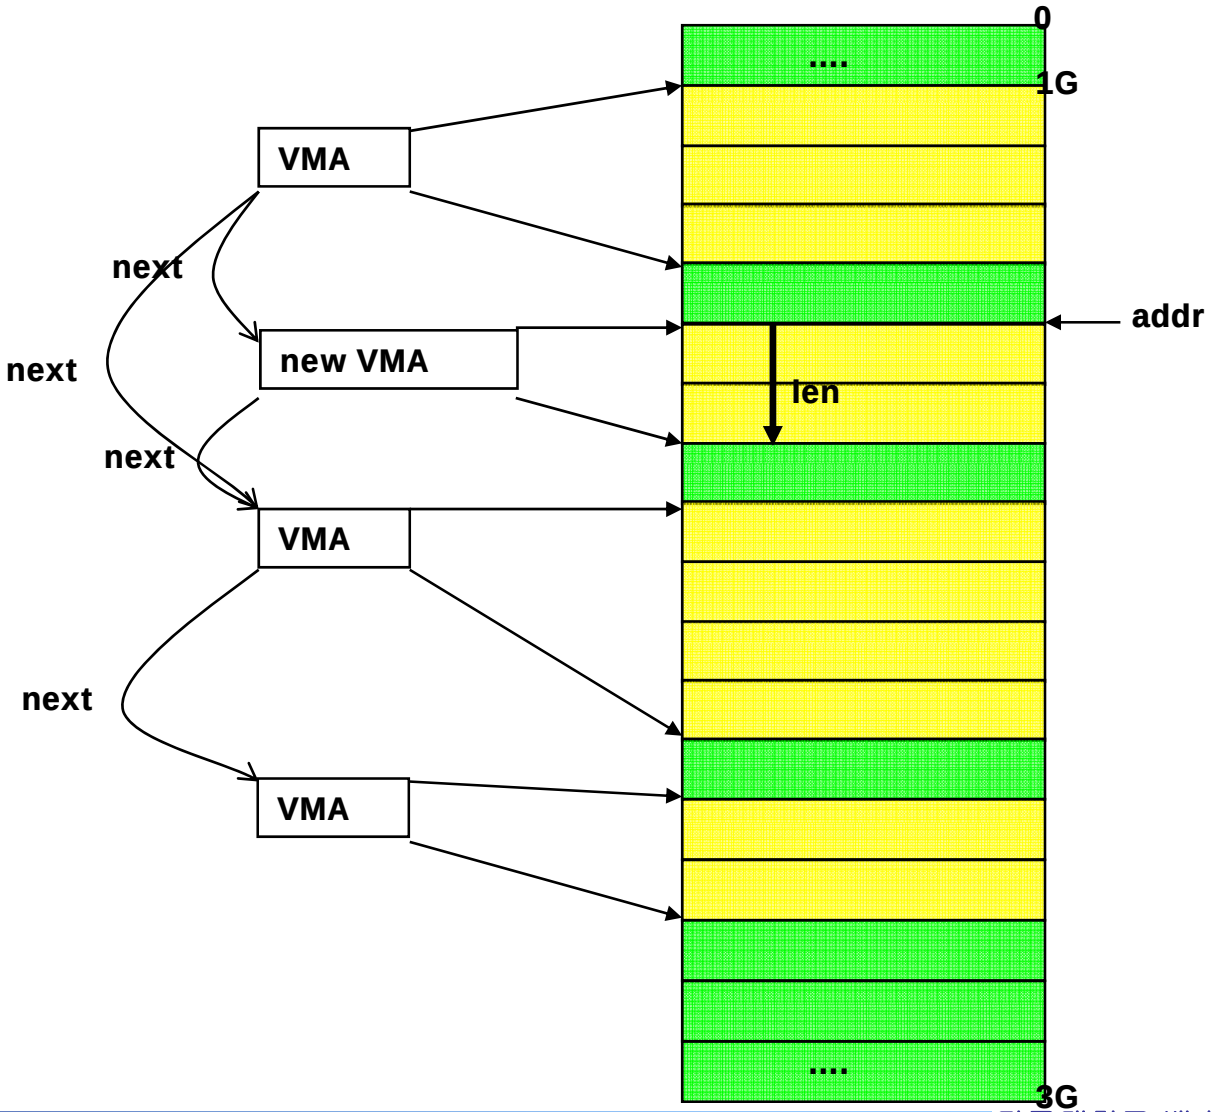

Merging contiguous region

- do_mmap_pgoff
  - ✓ merge-able

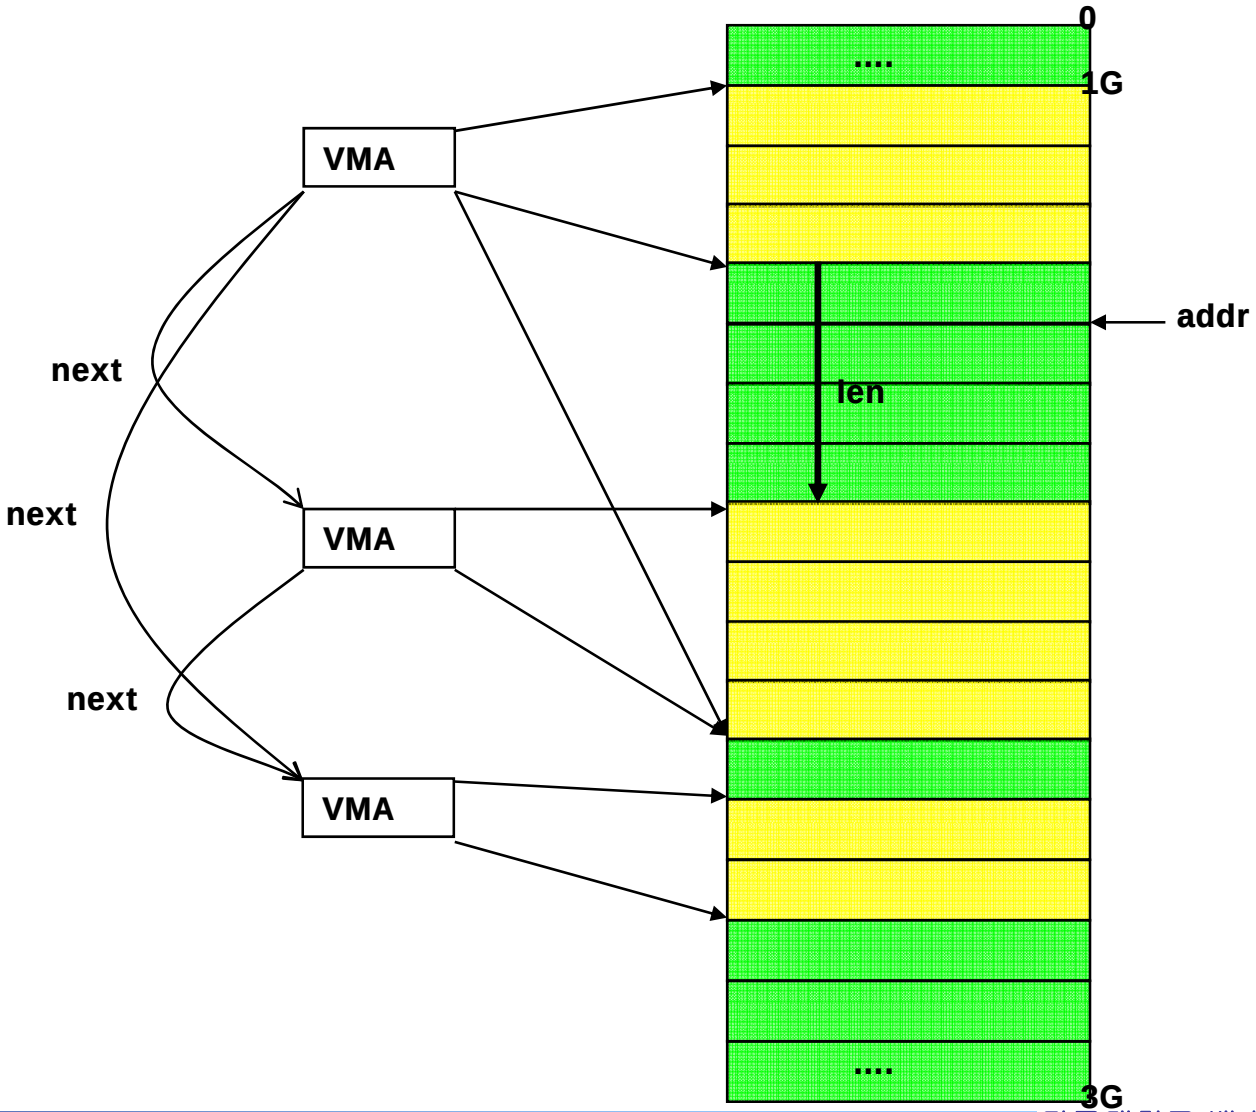

Remapping and Moving a memory region

- do_mmap_pgoff
  - ✓ memory region growing or shrink
  - ✓ find another region

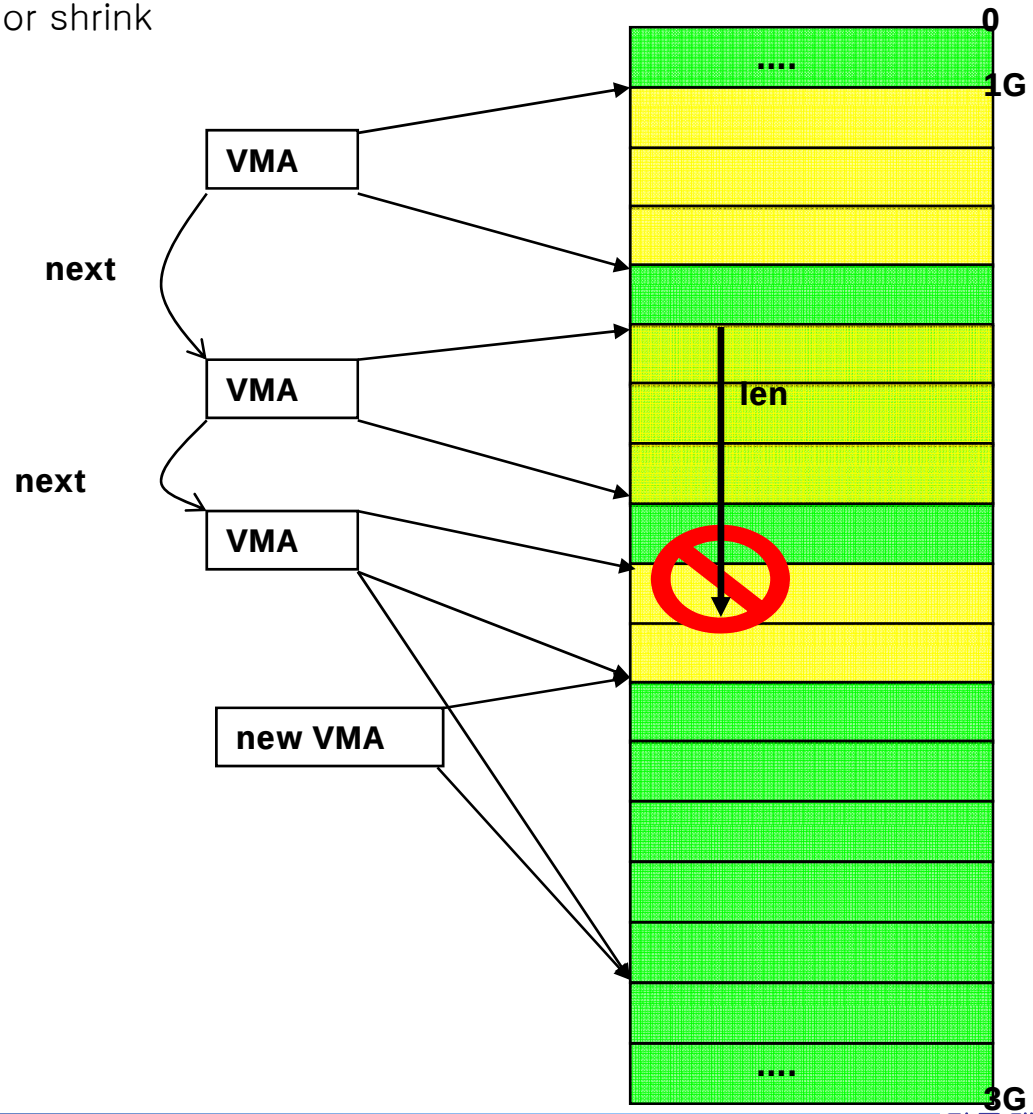

Delete a memory region

- do_munmap

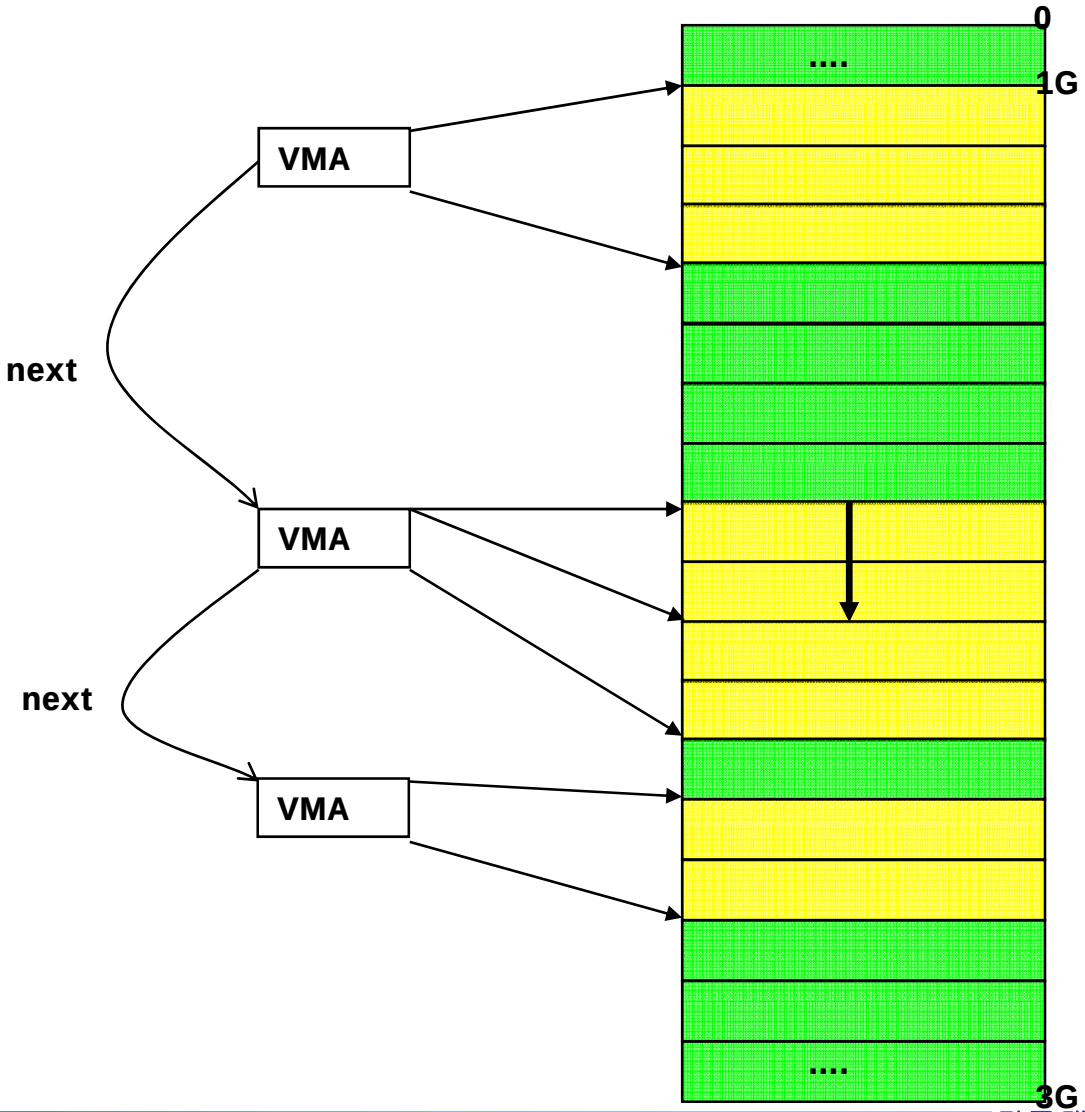

Delete a memory region

- do_munmap

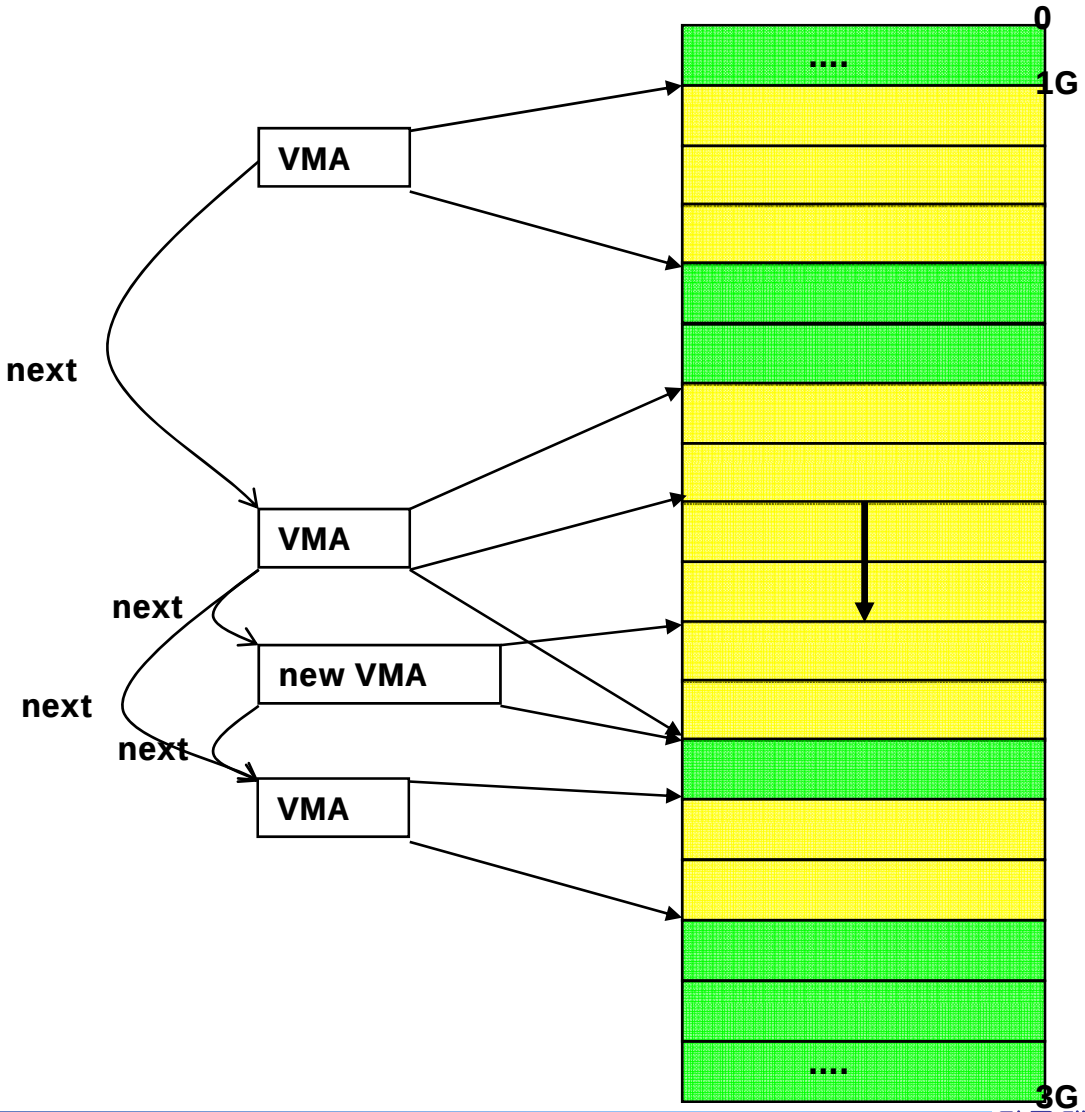

Linux의 Page Table Management 전체 구조

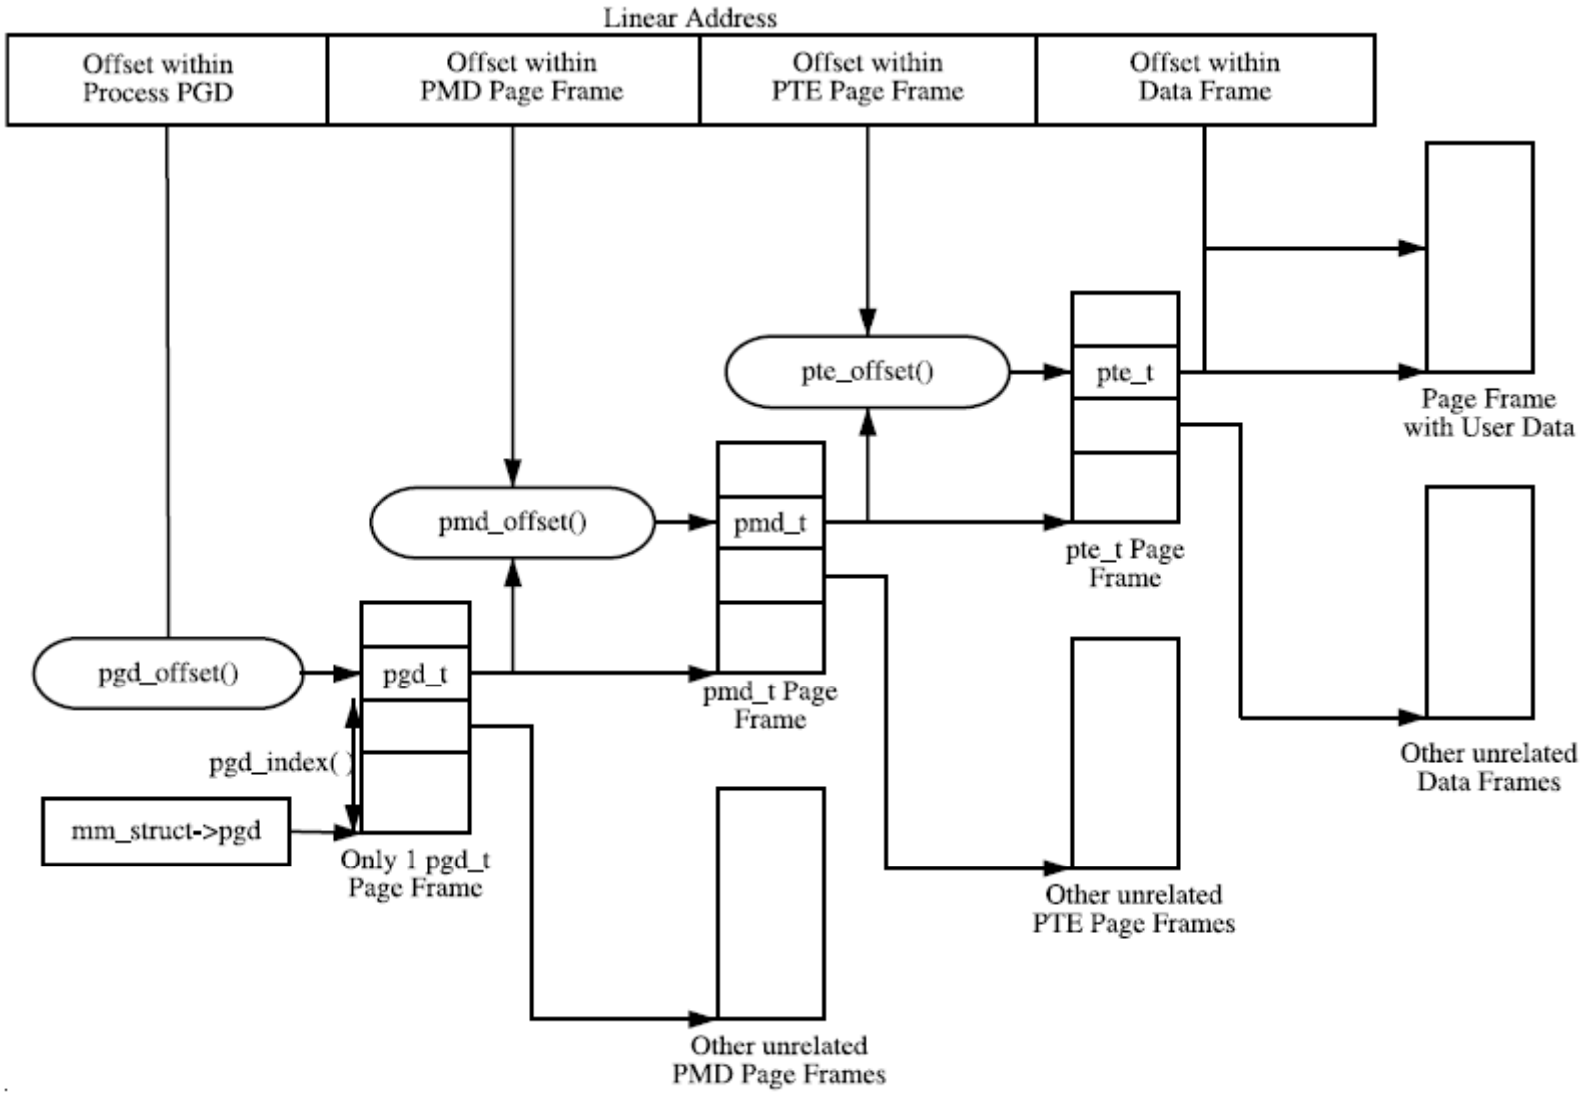

Linux의 PGD

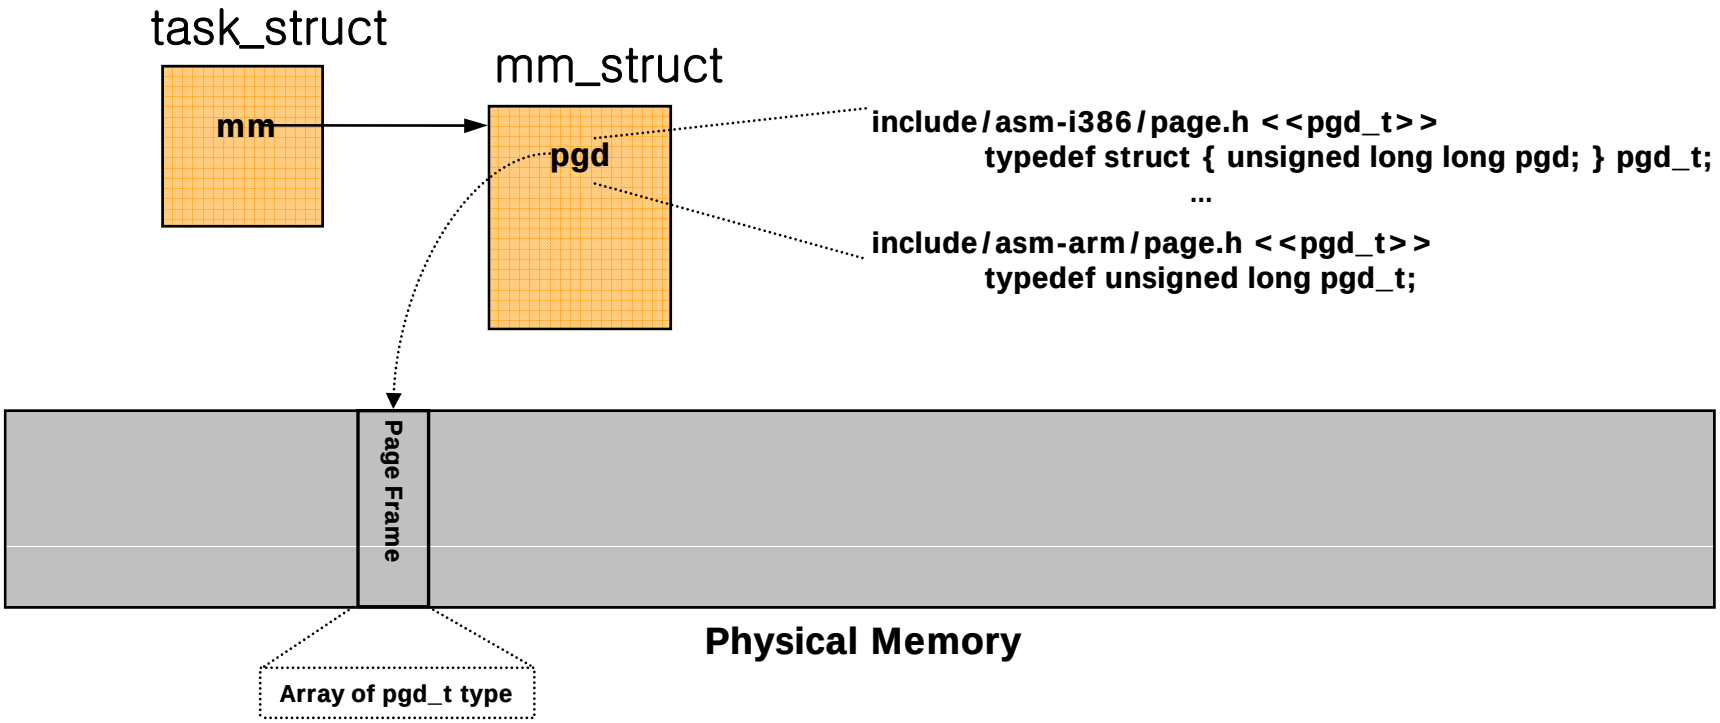

pgd 로딩?

X86 이라면 **mm->pgd**를 **cr3**에 복사함으로써 이뤄짐 ➔ **__flush_tlb()**
(cr3 복사는 **TLB flushing**을 유발하는 단점이 있음**)**

Linux의 PGD, PMD, PTE

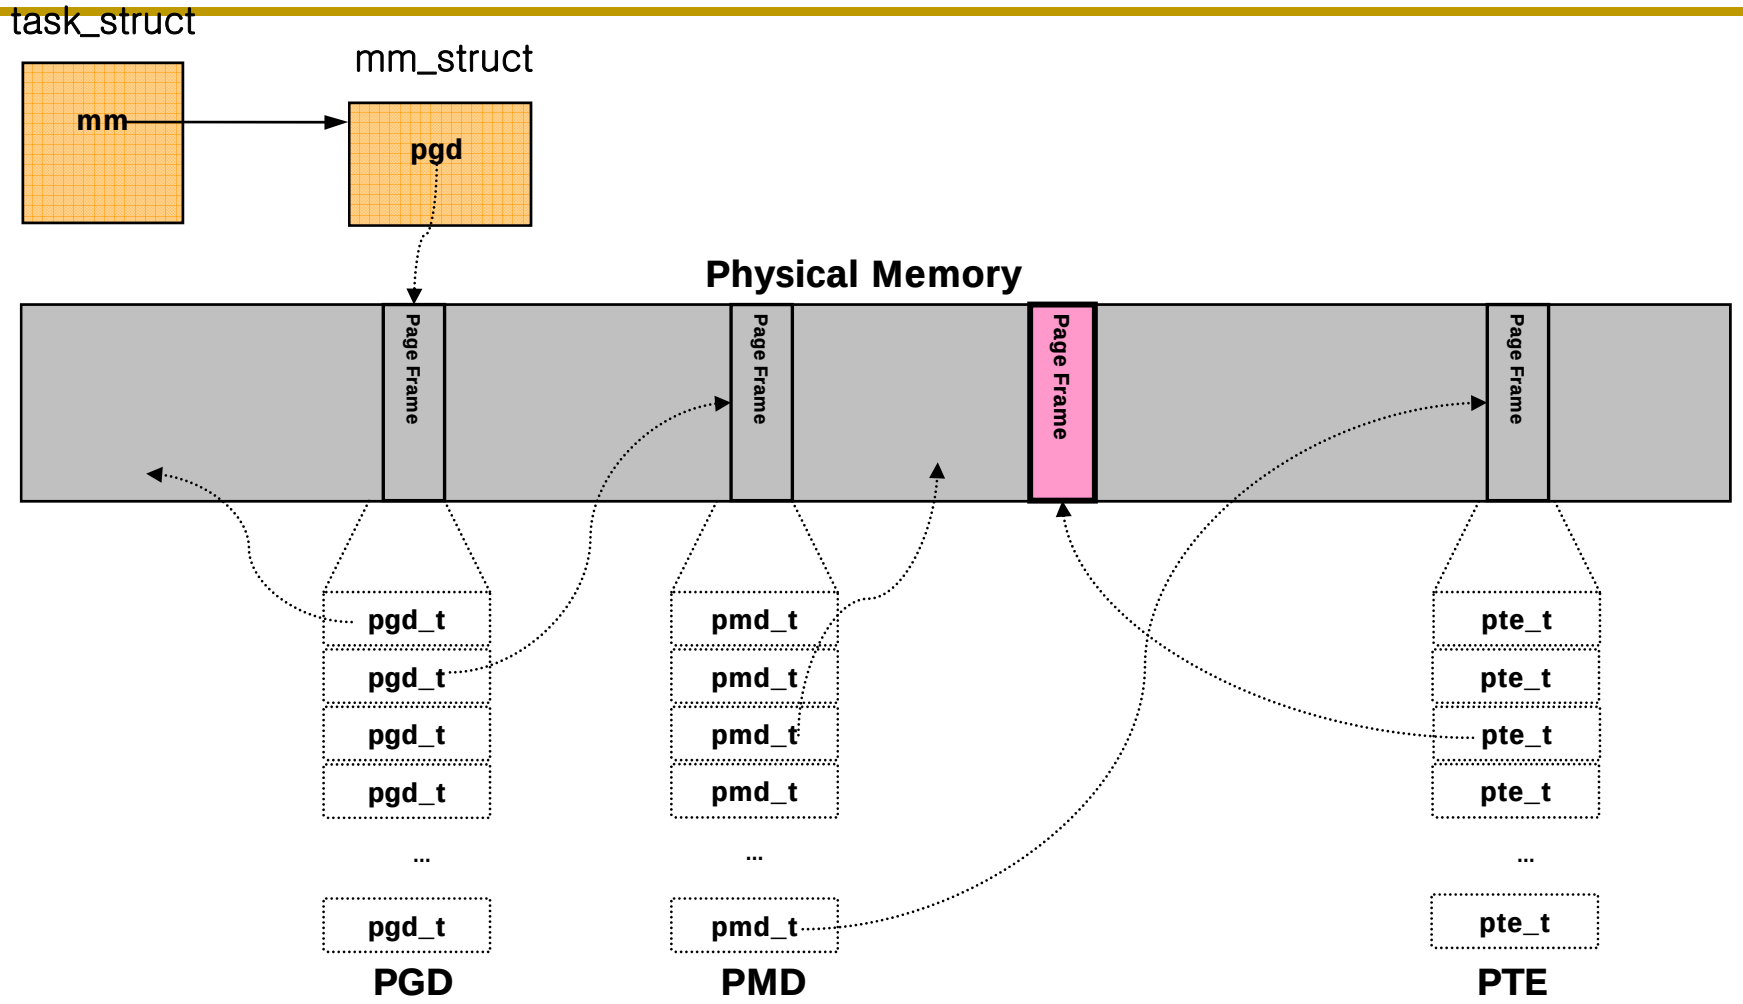

Swap out된 경우에는**?**

Swap entry가 **PTE**에 저장되어 있음
Fault 맞으면 이 **swap entry**를 이용해 **do_swap_page()** 함수가 **page**를 처리해 줌

주소 변환을 위한 매크로

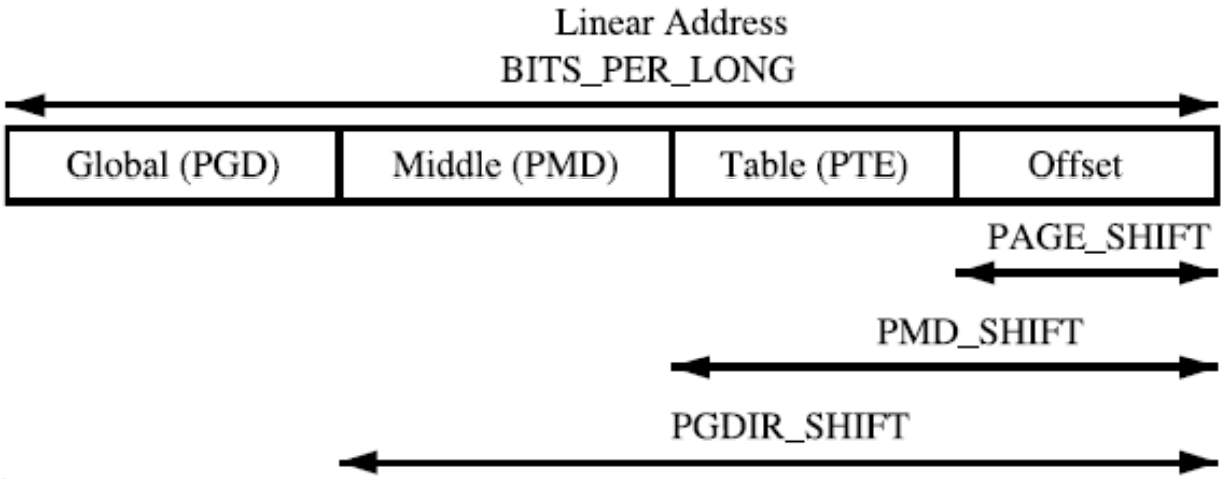
Linear Address
BITS_PER_LONG
Global (PGD)
Middle (PMD)
Table (PTE)
Offset
PAGE_SHIFT
PMD_SHIFT
PGDIR_SHIFT

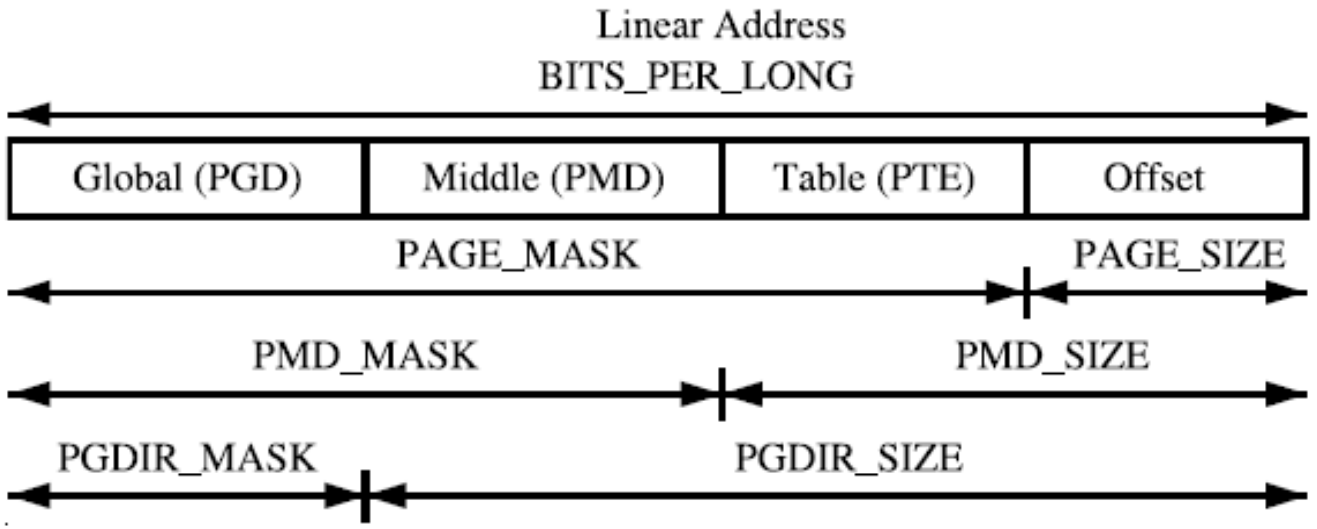
Linear Address
BITS_PER_LONG
Global (PGD)
Middle (PMD)
Table (PTE)
Offset
PAGE_MASK
PAGE_SIZE
PMD_MASK
PMD_SIZE
PGDIR_MASK
PGDIR_SIZE

주소 변환 과정의 이해

```
/* mm/memory.c */
static struct page * follow_page(struct mm_struct *mm, unsigned long address, int write)
{
        pgd_t *pgd;
        pmd_t *pmd;
        pte_t *ptep, pte;

        pgd = pgd_offset(mm, address);
        if( pgd_none(*pgd) || pgd_bad(*pgd))
                goto out;

        pmd = pmd_offset(pgd, address);
        if( pmd_none(*pmd) || pmd_bad(*pmd))
                goto out;

        ptep = pte_offset(pmd, address);
        if(!ptep)
                goto out;

        pte = *ptep;
        ....
}
```

인텔 처리기의 페이징

- 주소 변환

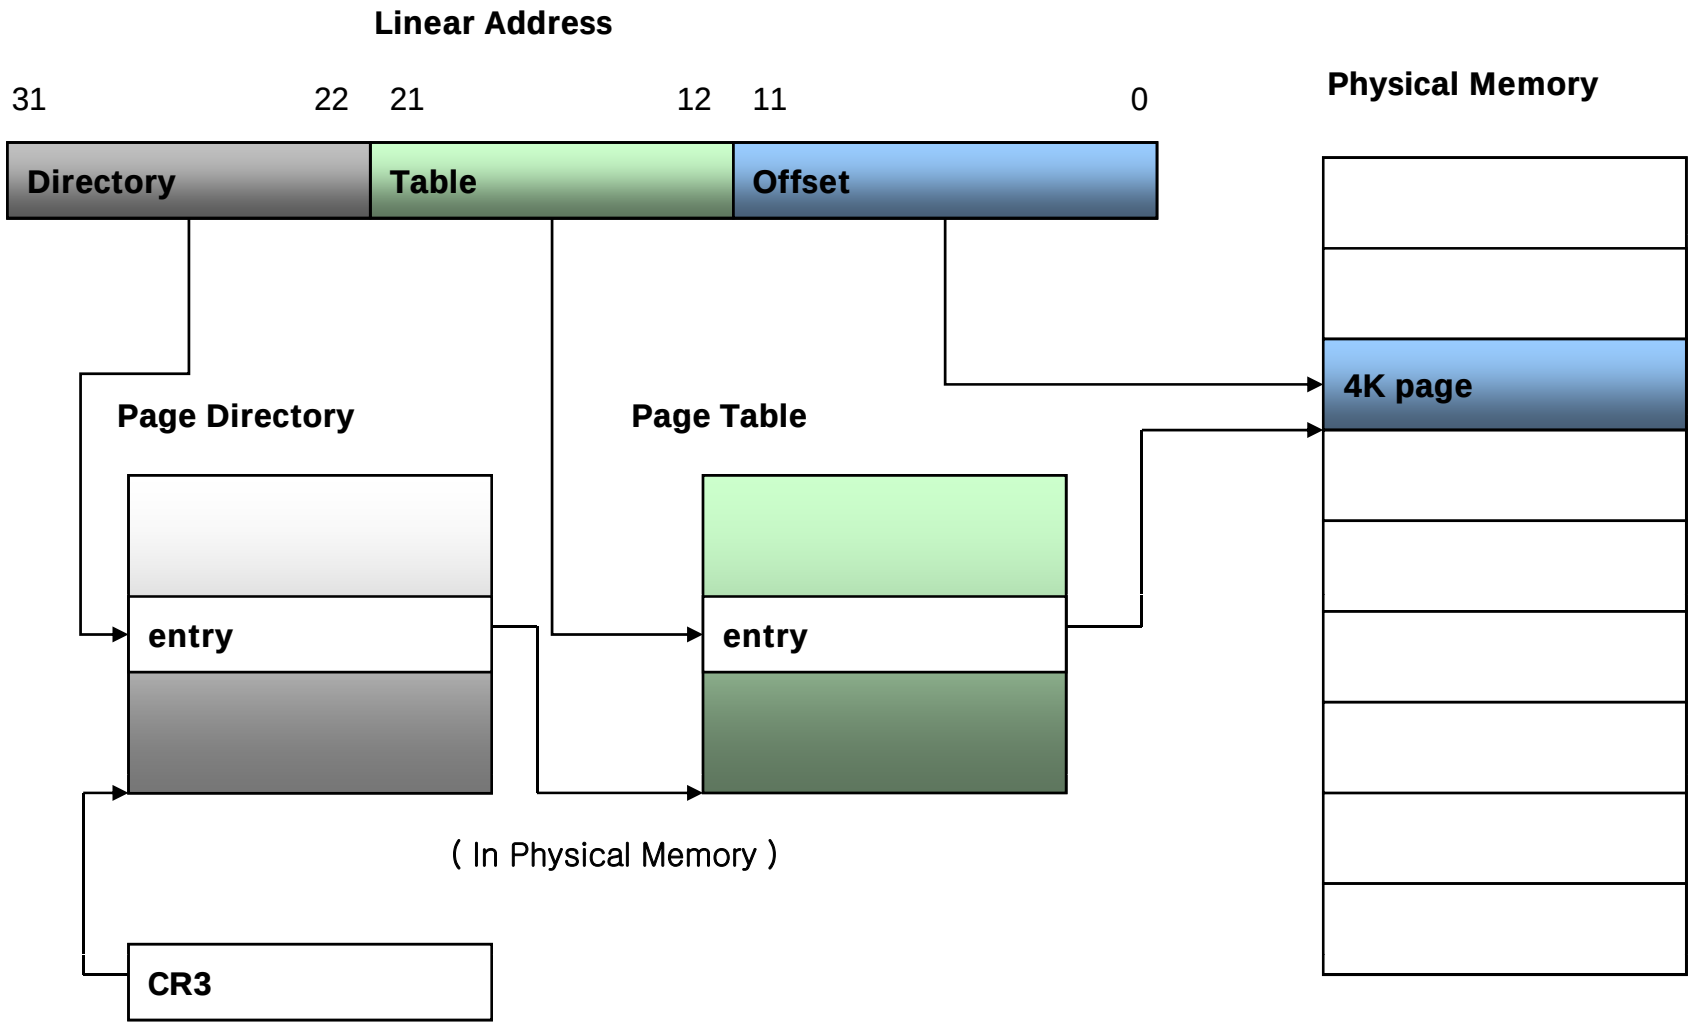

2.6.11부터 도입된 4단계 페이징(x86_64 기준)

- 64bit address translation
  - ✓ 4-level translation

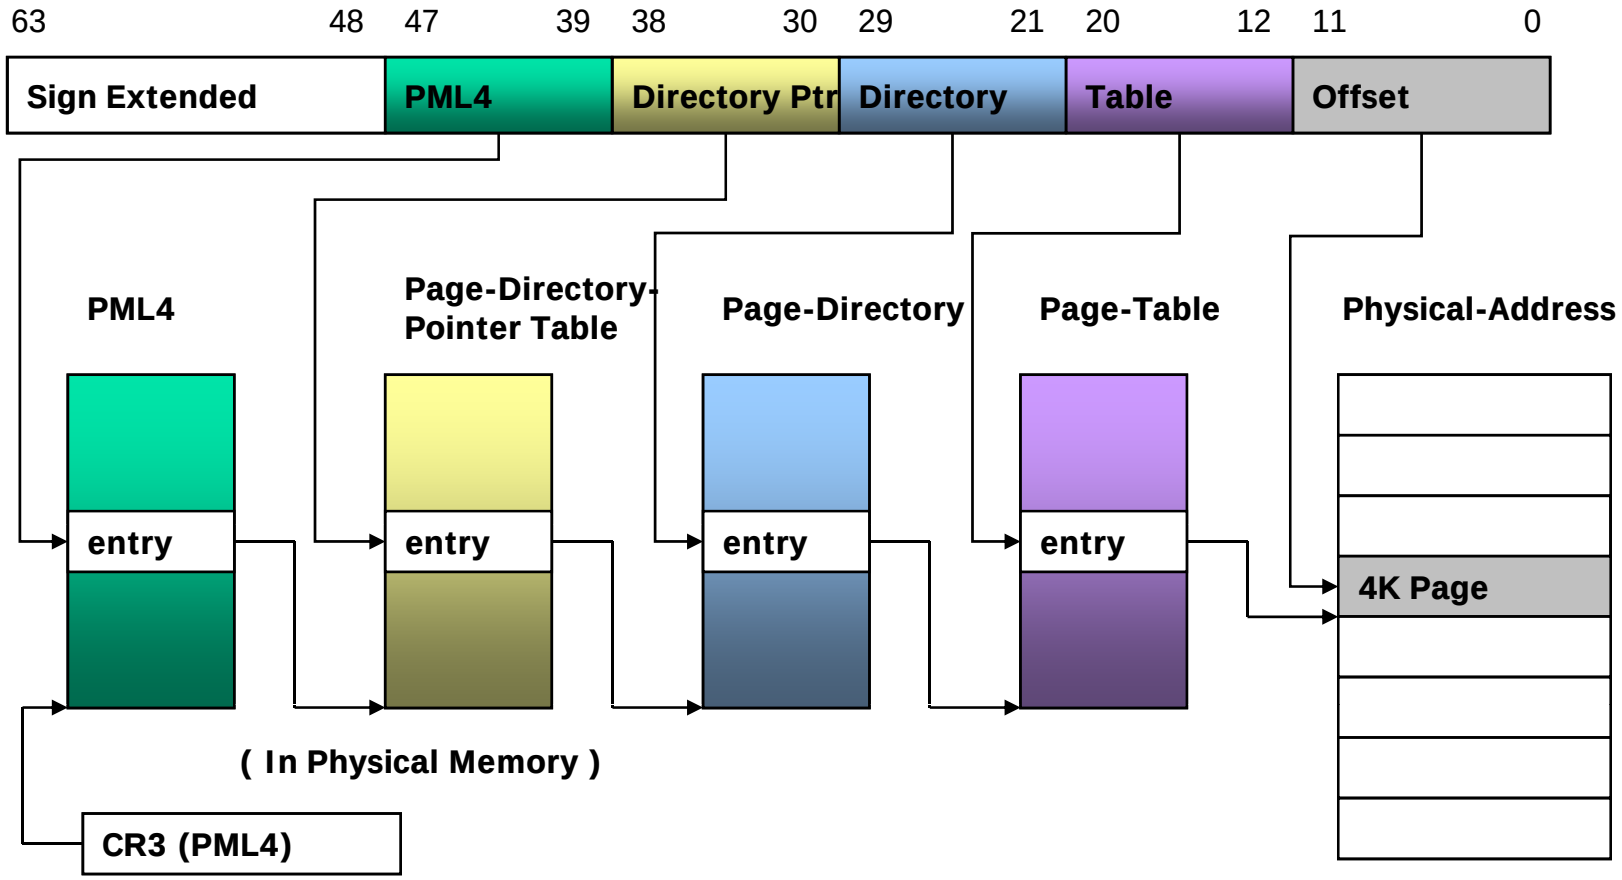

512 PML4 * 512 PDPTE * 512 PDE * 512 PTE = 2^{36} Page frames (256TB)

커널의 가상 주소 사용(32bit 처리기 기준)

- Kernel address space(32bit)

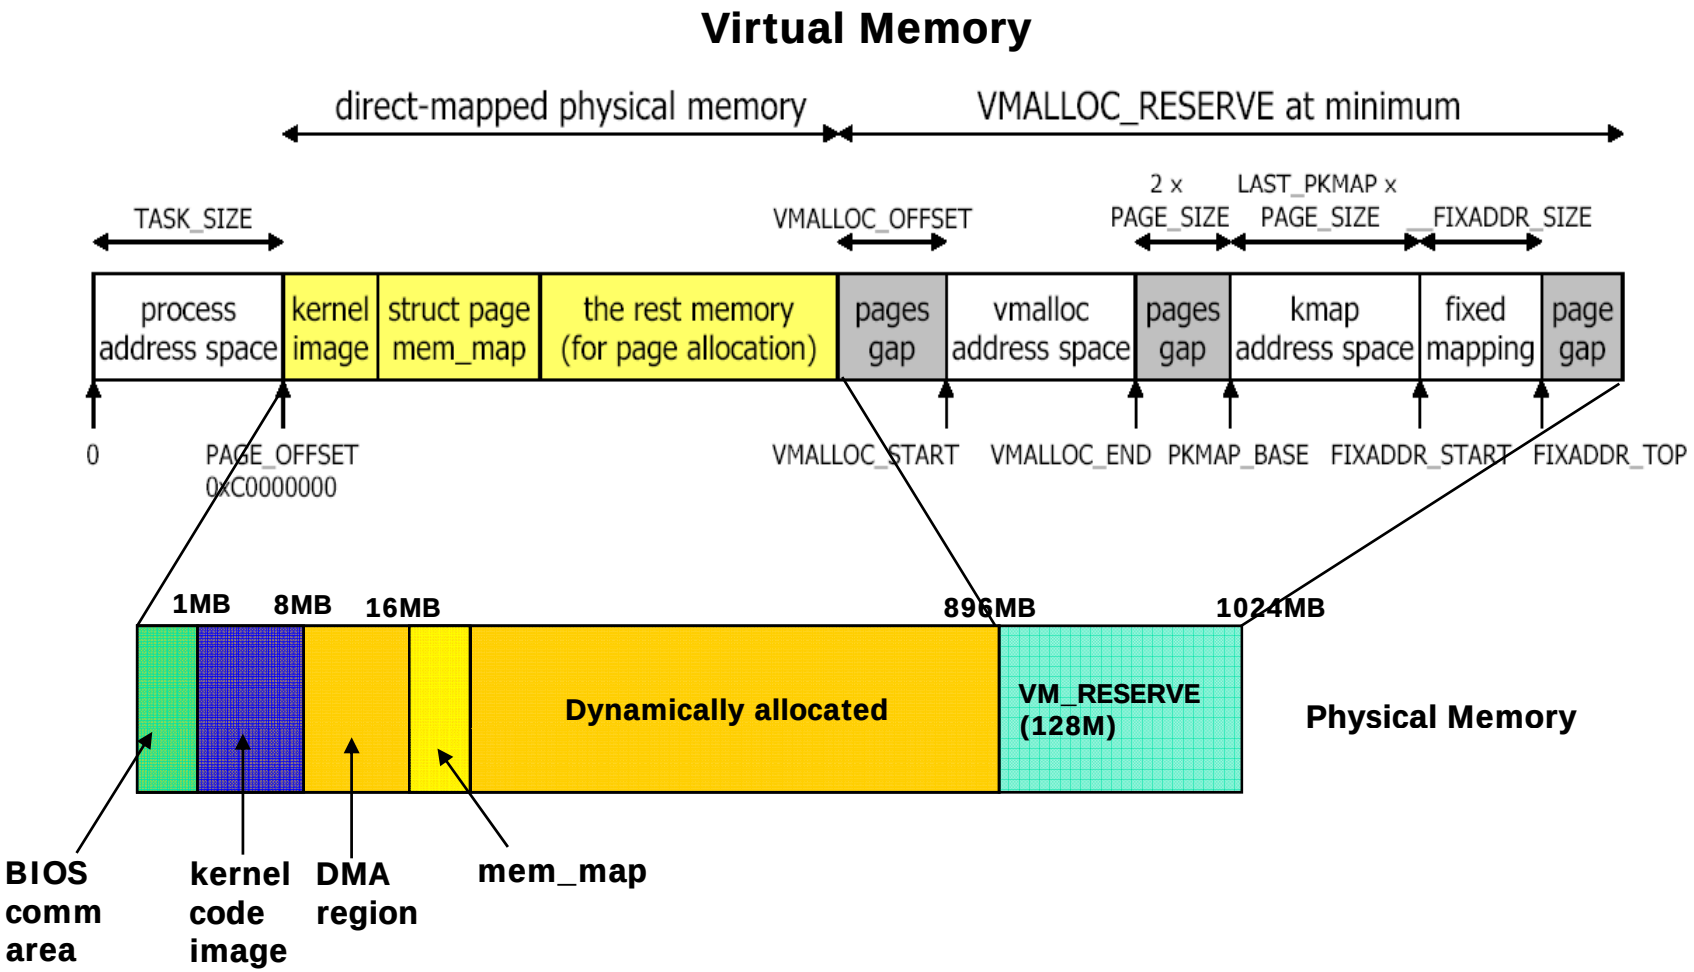

커널의 가상 주소 사용(64bit 처리기 기준)

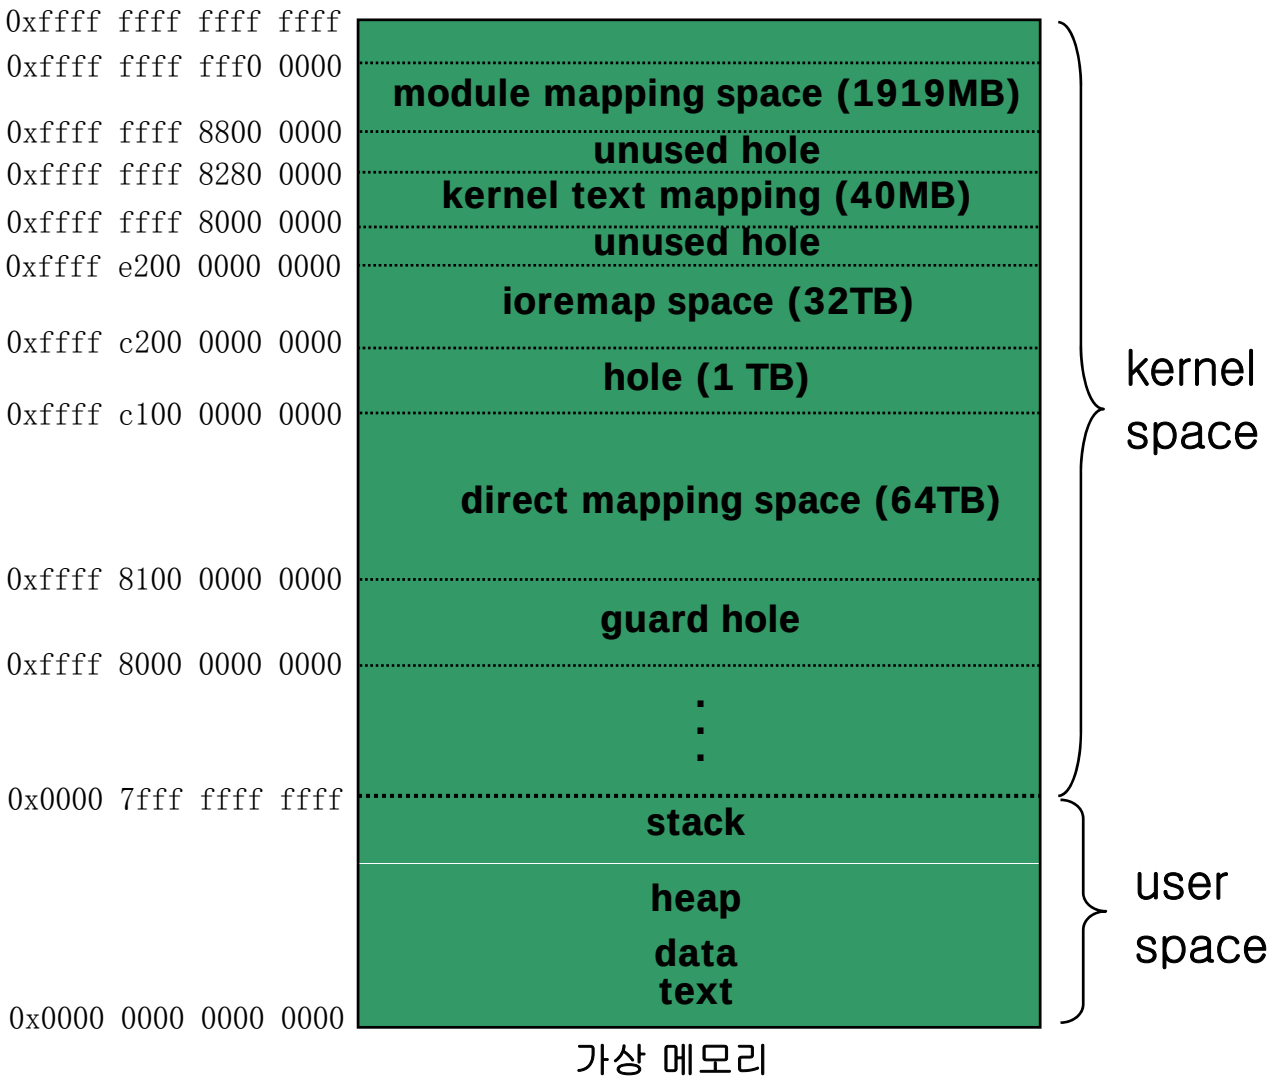

mm_struct

- mm struct <linux/sched.h>

```
struct mm_struct {
        struct vm_area_struct * mmap;
                //주소 공간내의 모든 VMA regions을 연결하는 linked list의 head
        rb_root_t mm_rb;
                //VMA는 빠른 탐색을 위해 red_black tree형태의 linked list로 구성된다.
                //이 필드는 tree의 root를 나타낸다
        struct vm_area_struct * mmap_cache;
                //마지막으로 find_vma()함수가 호출 되었을 때 검색된 VMA를 저장해 놓는 필드
                //이는 한번 사용된 VMA가 곧 다시 사용될 것이라는 가정에 기반한다.
        pgd_t * pgd;
                //이 프로세스를 위한 PGD
        atomic_t mm_users;
                //주소공간중 유저공간에 접근한 사용자의 카운트
        atomic_t mm_count;
                //1에서 부터 시작하는,real user를 위한 카운트 필드
        int map_count;
                //사용중인 VMA개수
        struct rw_semaphore mmap_sem;
                //이는 VMA list에 대한 R/W시에 보호를 위해 존재하는 lock이다.
                //이를 사용하는 유저들은 보통 장시간 사용하거나
                //락을 잡은 채로 sleep할수 도 있기때문에 spinlock은 적합하지 않다.
                //이 list를 read하려는 측에서는 down_read()를 통해 세마포어를 획득해야 한다.
                //만약 write를 하려면 down_write()를 통해서 권한을 획득해야 하며
                //추후 VMA를 업데이트 해야 하는 시점에는 page_table_lock 이란 이름의 spinlock을 획득 해야만 한다.
```

mm_struct

```
spinlock_t page_table_lock;
        //이는 mm_struct구조 전반에 걸친 보호 lock이다.
        //Rss와 VMA를 수정으로 부터 보호해주는 역할을 담당한다.
struct list_head mmlist;
        //모든 mm_struct 구조체는 이 필드를 통해 연결된다.
unsigned long start_code, end_code, start_data, end_data;
        //code영역의 시작과 끝, data영역의 시작과 끝을 나타냄
unsigned long start_brk, brk, start_stack;
        //힙영역의 시작과 끝, stack의 시작 부분을 나타냄
unsigned long arg_start, arg_end, env_start, env_end;
        //command line argument의 주소의 시작과 끝, environments의 시작과 끝을 나타냄
unsigned long rss, total_vm, locked_vm;
        //rss:이 프로세스를가 사용중인 page의 개수
        //global zero page는 RSS에 의해 카운트되지 않는다.
        //total_vm: 이 프로세스에 의해 점유되고 있는 전체 메모리 공간의 총합
        //locked_vm: 메모리상에 lock되어 있는 page의 개수
unsigned long def_flags;//VM_LOCKED한가지 값만이 가능함
        //이는 디폴트로 앞으로 일어날 모든 매핑이 lock될지를 결정하는 필드임
unsigned long cpu_vm_mask;
        //SMP system에서 모든 가능한 CPU를 나타내는 비트마스크
        //이는 IPI에의해서 CPU가 특정 함수를 수행해야 할지 말아야 할지를 결정할때 사용됨
        //이는 각 CPU의 TLB를 flush시키는 시점에 중요하게 사용됨
unsigned long swap_address;
        //이는 전체 프로세스가 스왑되어 버린 경우에 page out daemon이
        //어디서 swap 되었는지를 기록하는 데 사용하는 필드
unsigned dumpable:1;//prctl()에 의해 set되며, 이 필드는 process를 trace하고 있을때만 사용됨
mm_context_t context;//아키에 스페시픽한 MMU context
};
```

mm_struct와 가상 주소 공간 구조

- mm_struct 자료 구조 분석

include/linux/sched.h

```
struct mm_struct  {
    struct vm_area_struct *mmap;
    struct vm_area_struct *mmap_avl, *mmap_cache;
    pgd_t *pgd;
    atomic_t count;   int  map_count;
    struct semaphore mmap_sem;
    unsigned long context;
    unsigned long start_code, end_code, start_data;
    unsigned long end_data, start_brk, brk,
start_stack;
    unsigned long arg_start, arg_end, env_start,
env_end;
    unsigned long rss, total_vm, locked_vm,
def_flags;
    unsigned long swap_cnt, swap_address;
    void *segment;
}
```

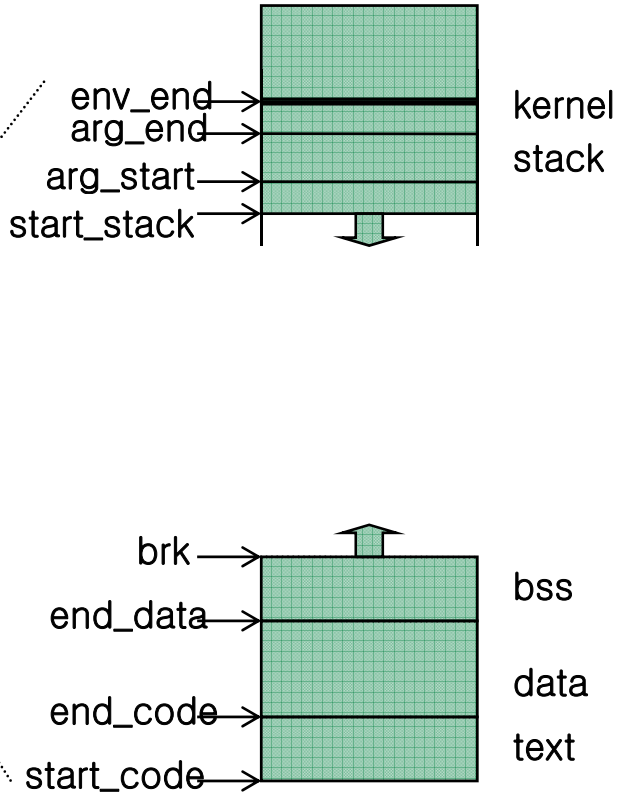


```
typedef struct {unsigned long pgd;} pgd_t;
```

/* include/asm-i386/page.h */

Memory Region

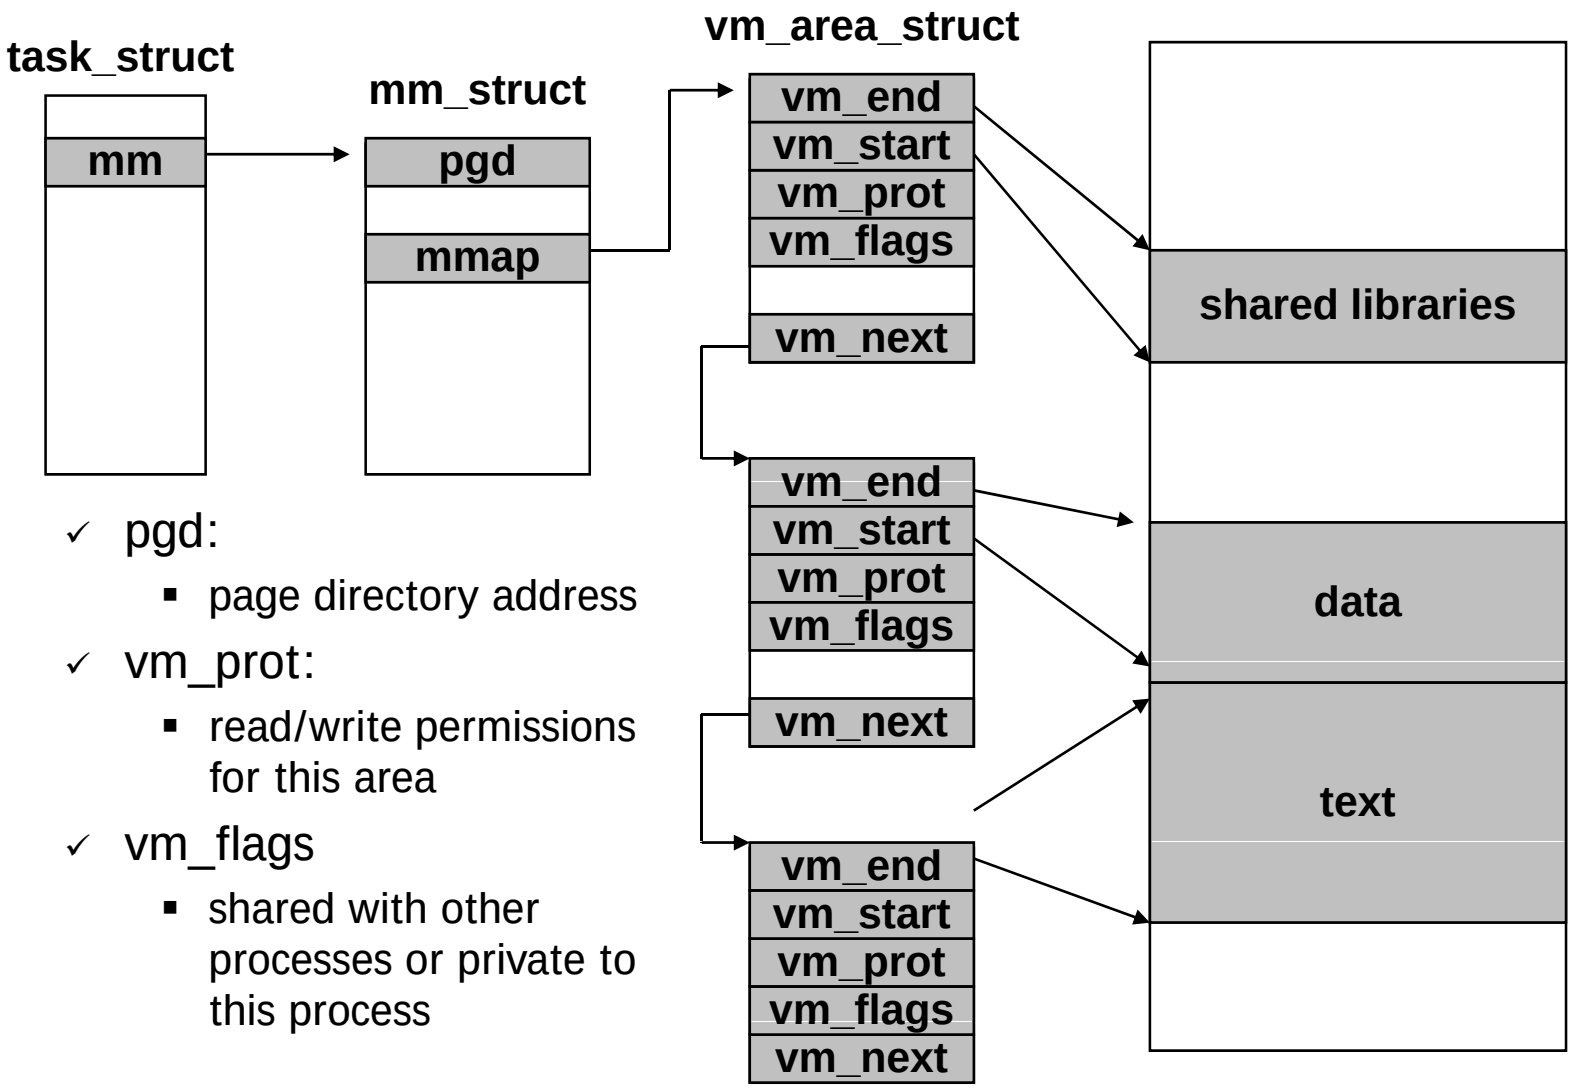

- ✓ pgd:
  - page directory address
- ✓ vm_prot:
  - read/write permissions for this area
- ✓ vm_flags
  - shared with other processes or private to this process

vm_area_struct 자료 구조

```
struct vm_area_struct {
        struct mm_struct * vm_mm;          //이 VMA가 속해있는 mm_struct
        unsigned long vm_start;            //regions의 시작 주소
        unsigned long vm_end;              //regions의 end 주소
        struct vm_area_struct *vm_next;    //주소공간내의 모든 VMA는 이 필드를 통해 single linked list로 연결됨

        pgprot_t vm_page_prot;             //이 VMA내의 PTE에 적용되는 protections bit. 표 3.1 참조
        unsigned long vm_flags;            //VMA의 특성과 protections을 나타내는 flags
        rb_node_t vm_rb;          //list로 연결되어 있는 VMA구조에서 빠른 검색을 위해 VMA를 red-black tree로 관리한다.
                                  //이는 특히 대용량의 공간이 매핑되어있는 상황에서 페이지 폴트가 발생하여
                                  //빠르게 적합한 regions을 찾는것이 중요한경우 중요하게 사용될수 있다.
        struct vm_area_struct *vm_next_share;    //shared library처럼 파일 매핑에 기반한 shared VMA를 link하는 필드
        struct vm_area_struct **vm_pprev_share;          // vm_next_share의 반대 작업
        struct vm_operations_struct * vm_ops;            //open(), close(), nopage()에대한 함수 포인터를 담고 있다.
                                                         //disk와 data를 sync할때 사용됨
        unsigned long vm_pgoff;            //메모리 맵되어 있는 파일인 경우 page단위로 aligned되어 있는 offset
        struct file * vm_file;             //맵되어 있는 파일의 struct file에 대한 포인터
        unsigned long vm_raend;            //read-ahead window의 end address.
                                           //fault가 발생하면 실제 원하는 page에 딸려서 몇개의 page가 같이 올라온다.
                                           //이때 얼마나 많은 page가 딸려서 올라올지를 결정한다
        void * vm_private_data;       //memory manage에 관계없이 device driver가 자체적인 정보를 저장할 때 사용된다.
};
```

Linux 커널 메모리 관리 함수

- Interface
  - ✓ struct page * alloc_pages(unsigned int gfp_mask, unsigned int order)
    - 2^order 크기의 연속된 물리적 페이지들을 할당 후, 첫 페이지의 page 구조체 포인터를 리턴
  - ✓ void * page_address(struct page *page)
    - 매개변수로 넘긴 물리적 페이지가 현재 포함돼 있는 논리적 주소에 대한 포인터 반환
  - ✓ Wrapping Function
    - Page-level allocator : get_free_page()
      - 요청된 만큼의 연속된 메모리를 할당
    - Kernel-level allocator
      - 물리적으로 **연속**하며, 128KB이하 임의 길의의 메모리 할당 : kmalloc()
      - 물리적으로 **비 연속적인** 메모리 할당 : vmalloc()