

Age of Computers
Faktabok

IDI, NTNU

2005

Innhold

1	Introduksjon	7
1.1	Velkommen til AoC	7
2	Tallsystemer	10
2.1	Binære tall	10
2.2	Bits og bytes	11
2.3	Flyttallsrepresentasjon	12
2.4	Ariane 5	13
2.5	Patriotmissilet	15
2.6	Omregning fra ett tallsystem til et annet	15
3	Digitalteknikk	17
3.1	Multiplekser	17
4	Oversikt over datamaskinen	18
4.1	Datamaskinoversikt	18
4.2	Hovedkort	19
5	Instruksjoner	22
5.1	Instruksjonssett	22
5.2	Representasjon	23
5.3	Stakk	24
5.4	Antall operander	26
5.5	Big/Little/Bi endian	27
5.6	Instruksjonsformat	28
5.7	Adresseringsmodi	29
6	Assemblyprogrammering	33
6.1	Hvordan programmere assemblerspråk	33
6.2	Dark load-store-maskin	36
6.3	Dark Stakkmaskin	43
6.4	Introduksjon til Dark	51
7	Prosessorens oppbygning	53
7.1	Mikrooperasjoner	53
7.2	Prosessoren	55
7.3	Utførende enhet	56
7.4	Oversikt over prosessoren	59
7.5	Styreenheten	59

7.6	Eksempel på styreord	61
8	Samlebånd	65
8.1	Instruksjonssykel	65
8.2	Samlebånd og kontrollflyt	66
8.3	Dataavhengigheter	68
8.4	RISC og CISC	70
8.5	Instruksjonssykel i maskinvare	71
9	Eksempler på prosessorer	75
9.1	Intel x86	75
9.2	PowerPC	78
10	I/O	79
10.1	Introduksjon til I/O	79
10.2	Kommunikasjon mellom CPU og I/O-kontrollere	79
10.3	DMA	80
10.4	Busser	81
10.5	Eksterne busser	84
11	Primærlager	86
11.1	Oversikt over lageret	86
11.2	ROM	89
11.3	Feilkorrigering i primærlageret	90
11.4	Hurtigbuffer	92
11.5	Mer om hurtigbufferet	94
11.6	Primærlageret	94
11.7	RAM	95
12	Sekundærlager	98
12.1	Sekundærlageroversikt	98
12.2	RAID	99
12.3	Optisk plate	101
12.4	Magnetplate	101
12.5	Eksempel på beregning av lesetid	104
13	Trender og Forskning	106
13.1	Innvevde systemer	106
13.2	Trender	108
13.3	Biologisk inspirasjon	110
14	Oppsummering	115
14.1	Oppsummering: Hurtigbuffer	115
14.2	Oppsummering: Prosessoren	116
14.3	Oppsummering: Instruksjoner	117
14.4	Oppsummering: Primærlageret	118
14.5	Oppsummering: Lagerhierarkiet	119
14.6	Oppsummering: Primærkunnskaper	119
14.7	Oppsummering: I/O	120
14.8	Oppsummering: Sekundærlageret	121
14.9	Oppsummering: Annet	122

Figurer

2.1	Representasjon av flyttall	12
2.2	Ariane 5	14
2.3	Patriot	14
3.1	Multiplekser	17
4.1	Oversikt over en datamaskin	19
4.2	Hovedkort, komponenter	20
4.3	Hovedkort, tilkoblinger	20
5.1	Stakkeksempel	25
5.2	Skal man kappe egget i den store eller lille enden?	27
5.3	Big endian og Littel endian	28
5.4	Instruksjonsord	28
5.5	MIPS rformat	29
5.6	MIPS add	29
5.7	Immediate	30
5.8	Direkte	30
5.9	Indirekte	30
5.10	Register	31
5.11	Indirekte register	31
5.12	Displacement	32
5.13	Stakk	32
6.1	Load-store arkitektur i Dark	37
6.2	Stakk arkitektur i Dark	44
6.3	Darksimulatoren	51
6.4	Step	52
6.5	All step	52
7.1	Eksempel på logiske skift operasjoner	55
7.2	Utførende enhet og styreenhet	55
7.3	Utførende enhet	57
7.4	ALU	58
7.5	Styreord	58
7.6	Oversikt over prosessoren	60
7.7	Utførende enhet med funksjonstabell	62
8.1	Instruksjonssykel	65
8.2	MIPS samleband	73

9.1	Intel 4004	75
9.2	Intel 8008	76
9.3	Intel 8086	76
9.4	Intel 80386	77
9.5	Intel Pentium 4	77
10.1	I/O-kontrollere og enheter	80
10.2	Busshierarki	83
10.3	Synkron tidsstyring	84
10.4	Asynkron tidsstyring	84
11.1	Lagerhierarki	87
11.2	EPROM	89
11.3	Generell feilkorrigering	90
11.4	Hammingkode	91
11.5	Hurtigbuffer	92
11.6	Lagercelle	95
11.7	DIMM-kort	95
11.8	DRAM celle	96
11.9	SRAM celle	97
12.1	RAID	99
12.2	RAID 5	100
12.3	IDI filtjener	100
12.4	CDROM	101
12.5	DVD	102
12.6	Harddisk	102
12.7	Hvordan en harddisk ser ut inni	103
12.8	Plateutlegg	103
13.1	Moore's lov	109
13.2	Utvikling til prosessor og DRAM-hastighet	110
13.3	Tid/effekt-diagram for Intel-prosessorer	111
13.4	Phylogeny, Ontogeny and Epigenesis	111
13.5	Evolusjon av mennesket (Phylogeny)	112
13.6	Utviklingsprosessen fra en befruktet eggcelle (Ontogeny)	113
13.7	Et menneskelig neuron som «kan lære» (Epigenesis)	114

Tabeller

1.1	Ikonbeskrivelse	9
7.1	Styreordsformat	62
7.2	Styreord 1	62
7.3	Styreord 2	62
7.4	Styreord 3	64
7.5	Styreord 4	64
7.6	Styreord 5	64
7.7	Endelig styreord for $R6 \leftarrow R3 + \neg R0$	64
8.1	Samlebånd med kontrollflytinstruksjon	67
8.2	Samlebånd med dataavhengighet	69
8.3	Instruksjonsflyt gjennom samlebåndet	74
11.1	Kostnad ved bruk av feilkorrigerende kode	91

Kapittel 1

Introduksjon

1.1 Velkommen til AoC

Er du klar for å bli med ut i verden og lære om datamaskinen? Ja så klart du er. Før du starter skal du få en innføring i hva du leter etter og hva du bør plukke opp på veien.

1.1.1 Spilletets virkemåte

Spillet fungerer slik at du går rundt i en brettverden der du får mulighet til å hente inn kunnskap om datamaskinens oppbygning, funksjonalitet og historie. Du får også mulighet til å drille på kunnskapen du har lært ved å svare på spørsmål. For å komme videre må man svare riktig på en del spørsmål. Siden det kreves at du kommer i mål for å få godkjent øvingsopplegget er det viktig at du prøver å svare på de fleste spørsmål du kommer over. Under følger en forklaring av ulike egenskaper ved spillet. Underveis vil man også finne noen meldinger som kan gi deg et tips.

Kunnskapsbøker

All kunnskap du henter inn vil bli lagret i de tre bøkene dine, historieboken, faktaboken og oppgaveboken. I spillet er disse vist som tre knapper oppe i venstre hjørne. I begynnelsen vil faktaboken og historieboken bare vise en innholdsfortegnelse over hva du skal lære deg. Etterhvert som du plukker opp boksider i spillet vil man få aktivert lenker i innholdsfortegnelsen inne i bøkene. Ønsker du å lese sidene du har hentet inn trykker du først på boken deretter på lenken til siden du har aktivert. Oppgaveboken vil i utgangspunktet være tom, men vil fylles inn med alle spørsmål du har svart riktig på.

Spørsmål

I spillet finnes det flere ulike typer spørsmål: flervalgsspørsmål, kortsvarsoppgaver og programmeringsoppgaver. Programmeringsoppgavene går ut på å skrive assemblykode som utfører visse handlinger, og testes i en simulator. Bruk av simulatoren vil bli forklart senere i spillet.

Alle spørsmålsikon som er gule må man svare på. Når spørsmålsikonet blir grønt har man svart på nok spørsmål. De spørsmål som i utgangspunktet er grønne trenger man ikke å svare på for å komme videre og få godkjent øvingsopplegget. Når du svarer riktig på spørsmålene får du poeng. Din poengsum vil du finne oppe i venstre hjørne i spillet.

Pratevindu

Nederst i spillet finner man et pratevindu. I vinduet kan man snakke med alle som er på samme brett som deg. Det er også mulighet til å utføre ulike kommandoer. For eksempel kan man finne sin lokasjon i spillet ved å skrive `/loc` i pratevinduet. Gi kommandoen `/help` for å få en oversikt over tilgjengelige kommandoer.

Forflyttelse i spillet

Når man har svart på nok spørsmål innen et brett kan man forflytte seg videre til neste brett ved å gå på et teleporterikon som vist i tabell 1.1. Om man ikke har svart på nok spørsmål får man beskjed om dette på teleporteren.

Avslutte økt

Alt blir automatisk lagret, det er ikke nødvendig å logge seg ut. Bare avslutt nettleser eller gå til en annen side.

Tidsmaskin









Øverst til høyre på Gløshaugen-brettet (omtrent over «Dødens dal») finner du en mengde teleportere. Dette er en slags portal mot alle hovedbrett i spillet, og kan brukes for å forflytte deg frem og tilbake i spillet. Du får i begynnelsen bare tilgang til ett av disse brettene, men etterhvert som du svarer på flere spørsmål «åpnes» nye brett.

1.1.2 Beskrivelse av ulike ikoner i spillet

Tabell 1.1 viser hva de forskjellige ikonene i spillet betyr.

1.1.3 Klar, ferdig, gå...

Ja da har du det du trenger å vite for å sette i gang. Første tips til deg er å finne og plukke opp en ødelagte datamaskin som ligger her på Gløshaugen. Gå til høyre. Lykke til og god tur.

Ikon	Beskrivelse
	Ikonet representerer deg som spiller eller andre spillere du møter på underveis.
	Ikonet representerer en spørsmålsgruppe hvor du <i>ikke</i> har svart på nok spørsmål. Går du på dette ikonet vil du få opp spørsmålet du skal svare på. Når du har svart på nok spørsmål vil spørsmålsteget endres til ikonet under.
	Ikonet representerer en spørsmålsgruppe hvor du har svart på nok spørsmål. For å komme videre må alle spørsmålsteget som er i en bestemt verden være slik. Fortsetter du å svare på spørsmål vil du kunne få flere poeng. Når du har svart på alle spørsmålene innen en gruppe blir ikonet borte.
	Ikonet representerer en side i historieboken. Går du på dette ikonet vil du få opp en historieside. Ikonet vil bli borte når man har plukket opp siden.
	Ikonet representerer en side i faktaboken. Går du på dette ikonet vil du få opp en faktaside. Ikonet vil bli borte når man har plukket opp siden.
	Ikonet representerer en teleporter. Går du på ikonet blir du transportert til et annet brett, så sant du har svart på nok spørsmål.
	Ikonet representerer en teleporterdestinasjon. En teleporter et annet sted sender deg til denne plassen. Noen av disse inneholder også en melding.
	Ikonet representerer en melding. Går du på ikonet får du opp en melding som enten forteller en historie eller som gir deg tips om hvor du bør gå.

Tabell 1.1: Ikonbeskrivelse

Kapittel 2

Tallsystemer

2.1 Binære tall

Vi mennesker bruker vanligvis titallsystemet i dagligtale og tanke. Det betyr at vi har ti forskjellige siffer (0–9), og større tall enn 9 lager vi ved å sette sammen flere siffer. Titallsystemet sies å ha *base 10*.

Binære tall, dvs. tall som benytter base 2, finnes overalt rundt oss. Et siffer i et binært tall kalles en *bit*. Binære tall er bl.a. brukt i den datamaskinen du har framfor deg nå. Binære tall brukes i logiske kretser og boolsk algebra.

I senere tid har oktale tall (8-tallsystemet) og hexadesimale tall (16-tallsystemet) kommet til. Binære tall benyttes fordi logiske uttrykk kan være enten ja eller nei (1 eller 0). Derfor passer tall med base 2 fint. Oktale tall er nyttige fordi de kan brukes til å representere grupper på 3 binære siffer (3 binære siffer kan benyttes til å telle fra 0 til 7). Hexadesimale tall er tilsvarende nyttige fordi de kan brukes til å representere grupper på 4 binære siffer.

2.1.1 Fortegn

Ved bruk av binære tall, hvordan skal disse kunne representere negative tall?

Sign-magnitudo

Ved bruk av sign-magnitudo reserveres det mest signifikante bitet (dvs det sifferet som står lengst til venstre) til å angi fortegn. Resten angir tallets absoluttverdi. Dersom fortegsbitet er satt er tallet negativt.

Ulempen med dette er at vi får to måter å skrive 0 på; -0 og +0.

Toerskomplement

Den måten som i (nesten) alle tilfeller benyttes i dag er toerskomplement. Har du et binært tall på toerskomplement form kan du finne det negative tallet med samme absoluttverdi ved å invertere alle bitene og legge til én. Samme fremgangsmåte for å finne det positive tallet hvis du har et negativt binært tall. Den generelle formelen ser slik ut:

$$-X = \neg X + 1$$

Denne metoden har flere fordeler. Vi har fremdeles egenskapen at mest signifikante bit sier hvilket fortegn tallet har. Toerskomplements form har også mange fordeler med hensyn på aritmetikk.

2.2 Bits og bytes



I en datamaskin snakker vi ofte om bits og bytes. En bit er den elementære lagringsenheten i en datamaskin. Denne kan være enten 0 (nei, usann, av) eller 1 (ja, sann, på). Bits (BInary digiTS) representeres derfor med totallsystemet. En byte er en samling med 8 bits. Dette er ofte den minste enheten man kan håndtere uavhengig i en datamaskin. 8 bits kan settes sammen på 256 forskjellige måter og kan derfor representere alle tall fra 0 til 255. Heksadesimale tall er veldig praktiske til å representere grupper på 4 bits, og benyttes derfor ofte til å representere innholdet i en byte (som består av to grupper på fire bits).


Her kommer en liten oversikt over hva bits og bytes er for noe:

- En bit (forkortes «b») er enten en 0-er eller en 1-er.
- 1 byte (forkortes «B») består av 8 bits.
- 1 kB (kilobytes) = 1024 bytes
- 1 MB (megabytes) = 1024 kB = $1024 \cdot 1024$ bytes = 1048576 bytes
- 1 GB (gigabytes) = 1024 MB
- 1 TB (terrabytes) = 1024 GB

Grunnen til at man multipliserer med 1024 i stedet for det mer naturlige 1000, er at man ønsker tall som passer med totallsystemet og ikke titallsystemet. $1024 = 2^{10}$.

Du vil også møte på uttrykket «dataord» (eller bare «ord» evt. «word»). Dette er en mer generell betegnelse på en lagringsenhet som består av flere bit. En byte er således et 8-bits ord.

Det er viktig å være konsekvent på bruk av stor/liten b for å skille mellom byte og bit. Dette er ikke alltid gjennomført i «den store verden» der reklameannonser og artikler ofte slurver. Du bør også huske på at kilo forkortes med liten k, og mega forkortes med stor M. Skriver du mb betyr dette egentlig millibit, dvs. en tusendedels bit, og det gir ikke mening.



Figur 2.1: Representasjon av flyttall

2.3 Flyttallsrepresentasjon

Tall kan representeres på flere måter. Det vanligste og enkleste i en datamaskin er *heltall*. En byte kan inneholde alle hele tall fra 0 til 255, eller dersom man ønsker tall med fortegn; fra -128 til 127. Tilsvarende kan man lage større heltall ved å benytte seg av dataord med 16, 32 eller 64 bits.

En annen representasjon er *fastpunkt* (fixed point). Her setter man av et fast antall bits til tall før og etter komma. F.eks kan man dele en byte inn i 5 + 3, der man har 5 bits til å representere heltallet før komma, og 3 bits til å representere tallet etter komma. Dette er en enkel måte å lage kommatall på i en datamaskin som dessuten kan behandles raskt og nøyaktig av en datamaskin.

Dersom ingen av disse metodene strekker til, kan man benytte *flyttall*. Dette er den mest kompliserte måten å representere tall på for en datamaskin. Heltall og fastpunkt har et begrenset tallintervall, men like god presisjon over hele intervallet. Bruker man fastpunkt med god presisjon (mange bits for tallet etter komma), har man få bits igjen til tallet før komma, og intervallet blir lite. Tanken bak flyttall er å prøve å gi både i pose og sekk: Både stort intervall (kunne representere store tall), og god presisjon for små tall.

Flyttall benytter seg av samme metode som vi gjør med penn og papir: Vi innfører en eksponent. Skal vi skrive store tall, f.eks 149 000 000 000 000, skriver vi ikke tallet ut fullstendig men benytter en tier-eksponent: $1,49 \cdot 10^{14}$. Dette tallet er svært stort, men har svært liten presisjon. Neste tall vi kan representere med samme antall siffer er $1,50 \cdot 10^{14}$, som er 10^{12} større! Det positive er at små tall har god presisjon. Tallene $1,49 \cdot 10^{-14}$ og $1,50 \cdot 10^{-14}$ har bare en differanse på 10^{-16} .

Dette kalles flyttall fordi posisjonen til komma endrer seg etter hvor stort tallet er. Store tall har få eller ingen siffer etter komma, mens små tall har mange siffer etter komma.

Samme triks benyttes av flyttall i en datamaskin bortsett fra at man bruker totallsystemet.

Hvert tall kan skrives på formen: $\pm S \cdot B^{\pm E}$, hvor S står for signifikand (kalles av og til mantisse), B for basen og E for eksponent. Når man representerer flyttall i en datamaskin (binært) bruker man en base på $B = 2$.

Figuren viser hvordan et flyttall kan lagres i en datamaskin. Dette formatet følger IEEE's 32-bits flyttallsstandard. Vi har tre felt:

- fortegn
- signifikand
- eksponent + bias

Den våkne leser vil se at basen ikke lagres, den er nemlig 2 for alle tall i en datamaskin.

Alle flyttall i en datamaskin lagres normalisert. Dette vil si at de er på formen $1,xxx \cdot 2^{xxx}$. Dette gjør at vi ikke trenger å lagre sifferet før komma, fordi det alltid er 1. Signifikanden representerer altså sifrene etter komma. Eksponenten representeres ofte forskyvet (eng: biased). Det vil si at man lagrer tallet $E + \text{bias}$ i stedet for å lagre E direkte. Dersom eksponenten er på 8 bit vil man typisk ha en bias på 127. Dette gjøre at man kan ha negative eksponenter og likevel klare seg med å lagre bare positive tall (0 til 255) i eksponentfeltet. Bias er konstant og trenger derfor ikke lagres sammen med hvert tall.

Som et eksempel tar vi tallet 4,25.

- Først må vi forandre dette til binær form: 100,01
- Deretter må det normaliseres: $1,0001 \cdot 2^2$
- Fortegnsbitet blir 0
- Eksponenten er 2, og vi lagrer derfor $127 + 2 = 129(10) = 10000001(2)$
- Signifikanden blir 0001
- Vi ender da opp med dette: 0 10000001 000100000000000000000000

Her er noen andre eksempler på hvordan vi lagrer noen gitte binære flyttall:

- $1.1010001 \cdot 2^{10100} = 01001001110100010000000000000000$
- $-1.1010001 \cdot 2^{10100} = 11001001110100010000000000000000$
- $1.1010001 \cdot 2^{-10100} = 00110101110100010000000000000000$
- $-1.1010001 \cdot 2^{-10100} = 10110101110100010000000000000000$

Flyttall kan være veldig nyttig. Men man skal være svært påpasselig og restriktiv med å bruke disse i et dataprogram fordi avrundingsproblemer kan føre til uventede feil. Ofte vil det være bedre å benytte heltall eller fastpunkt hvis det er mulig fordi du da har bedre kontroll på tallenes presisjon.

2.4 Ariane 5

4. juni 1996 eksploderte den ubemannede raketten «Ariane 5», 20 sekunder etter at den ble skutt opp av European Space Agency. Raketten var på sin jomfrutur og hadde kostet 7 milliarder dollar å utvikle. Raketten og lasten den hadde med seg som ble ødelagt kostet ca. 500 millioner dollar. I ettertid har det vist seg at ulykken skyldtes en programvarefeil. I programmet som raketten brukte til å orientere seg med var det brukt 64 bits flyttall til å representere den vertikale hastigheten. Dette flyttallet var på et punkt i programmet konvertert til et 16 bits heltall, og under oppskytningen ble dette tallet over 32.768 som er den største verdien et 16bit heltall (med fortegn) kan ha.



Figur 2.2: Ariane 5



Figur 2.3: Patriot

2.5 Patriotmissilet

Under golfkrigen (25 februar 1991) mislyktes et amerikansk patriotmissilbatteri i Dharan å avskjære et innkommende irakisk Scud-missil. Scud-missilet slo ned i en amerikansk forlegning og drepte 28 soldater. Ulykken oppstod pga. en programvarefeil. Feilen lå i beregningen av hvor lang tid det var siden datasystemet som overvåket luftrommet var startet. Tiden, oppgitt i tidels sekund, ble ganget med $\frac{1}{10}$ for å få dette tallet i sekunder.

Denne beregningen ble gjort ved hjelp av et 24 bits fixed-point register. Brøken $1/10$ kan ikke representeres 100% nøyaktig i totallsystemet og ble rundet av slik at det passet i et 24 bits register. Denne lille tilnærmingen ga stort utslag når det ble multiplisert med et stort tall. Datasystemet hadde vært aktivt i 100 timer siden det sist ble omstartet. Avrundingen ga en feil på $9,5 \cdot 10^{-8}$. Hvis man multipliserer dette med antall tidels sekunder i 100 timer får man 0,34. Dette kan virke som en liten feil, men siden Scudmissilet har en hastighet på 1,676km/s vil missilet bevege seg ca. en halv kilometer på denne tiden.

Dette i seg selv hadde ikke vært noe problem, siden feilen ville ha blitt korrigert. Problemet var at enkelte steder i koden var feilen rettet opp, slik at ulike moduler av programvaren opererte med forskjellige posisjoner på missilet. Dette resulterte i at de ikke klarte å utføre oppdraget sitt.

2.6 Omregning fra ett tallsystem til et annet

2.6.1 Omregning til titallsystem

Bruk av andre tallsystemer enn titallsystemet kan virke forvirrende hvis man ikke er vant til det. Heldigvis finnes det en enkel formel for å konvertere et hvilket som helst tall til titallsystemet:

$$\sum_{i=-n}^{m-1} d_i r^i \quad (2.1)$$

- r er radix (base)
- m er antall tall til venstre for komma
- n er antall tall til høyre for komma
- d_i er det i -te tallet

Som et forklarende eksempel på denne formelen brukes det hexadesimale tallet $4d20_{(16)}$. Dette tallet har ingen tall til høyre for komma, så vi begynner med $i = 0$.

- Ta minst signifikante tall (0) og multipliser med basen (16) opphøyd i 0
- Ta nest minst signifikante tall (2) og multipliser med basen (16) opphøyd i 1
- Ta nest, nest minst signifikante tall ($d = 13$) og multipliser med basen (16) opphøyd i 2

- Ta mest signifikante tall (4) og multipliser med basen (16) opphøyd i 3
- Legg alle produktene sammen

Skrevet ut blir det slik: $(0 \cdot 16^0) + (2 \cdot 16^1) + (13 \cdot 16^2) + (4 \cdot 16^3) = 19744$
 Formelen fungerer for alle tallsystemer.

2.6.2 Omregning fra titallsystem

Tilsvarende er det viktig å kunne konvertere fra titallsystemet til et annet tallsystem. Formelen over kan omformes til å gå fra desimaltall til en annen base. Algoritmen vil se slik ut:

- Ta tallet og del med basen ($\frac{D}{r}$, der D er opprinnelig tall og r er basen). Resten vil da være $d0$ (minst signifikante tall i svaret)
- Ta heltallsdelen av svaret i punktet over og del med basen. Resten vil da være $d1$
- Gjenta forrige punkt helt til heltallsdelen blir 0

Vi bruker samme eksempel: Regn ut hva $19744_{(10)}$ blir i hex.

- $\frac{19744}{16} = 1234$, rest = 0
- $\frac{1234}{16} = 77$, rest = 2
- $\frac{77}{16} = 4$, rest = 13
- $\frac{4}{16} = 0$, rest = 4

Vi får da svaret $4d20_{(16)}$.


Kapittel 3

Digitalteknikk

3.1 Multiplekser

I digitalteknikken lærte du om logiske porter som bygger på Boole sin algebra. Disse portene kan settes sammen til mer komplekse enheter. Multiplekseren (MUX) er en slik enhet. En MUX er en kombinasjonskrets som har flere innganger og en utgang. I tillegg har den en kontrollinngang (kalles ofte «select» på engelsk). Kort fortalt er en MUX en slags bryter der du velger blant en av flere linjer. Kontrollinngangen brukes til å velge hvilken inngang som skal kopieres ut på utgangen. Multiplekserne har som oftest 2^n inngangslinjer og n bits kontrollinngang. Figuren under viser en enkel 4-til-1-linje multiplekser.

Her er D0-D3 inngangslinjer og S0 og S1 kontrollinngang. Funksjonstabellen viser hvilke verdier av S0 og S1 som fører til hvilke innganger som skal sendes til utgangen. Multiplekserer blir også kalt datavelgere siden de velger en av mange innganger og gir ut ett utgangssignal. MUX-er blir blant annet hyppig brukt i prosessoren, som du skal lære mer om senere.



Figur 3.1: Multiplekser

Kapittel 4

Oversikt over datamaskinen

4.1 Datamaskinoversikt

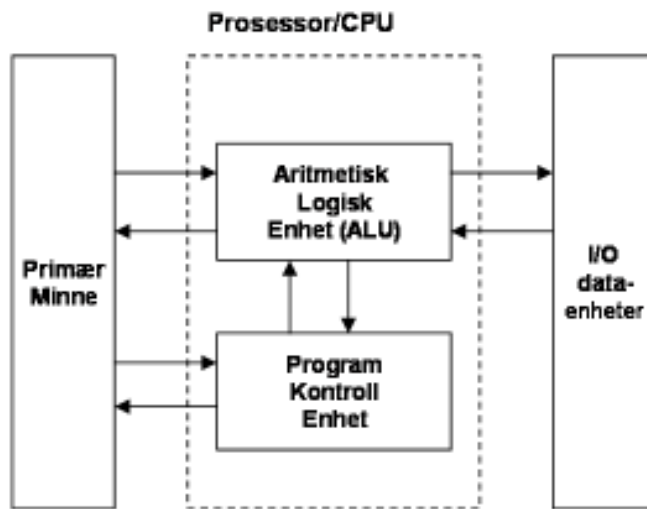
Det de fleste ser for seg når de tenker på en datamaskin er en PC med skjerm, tastatur og mus. Hvis man så fjerner skjermen, tastaturet og musen fra bildet, mener du fremdeles at det er en datamaskin? Vi kan ta det enda lengre, hva hvis vi fjerner harddisk, cd-rom diskettstasjon og lignende, vil det fremdeles være en datamaskin? Hva hvis du tok ut innmaten av kabinettet og brukte den uten kabinett?

De færreste tenker over hva som ligger i begrepet datamaskin, og begrepet har helt sikkert endret seg gjennom tiden. Hvis jeg skal forsøke å gi en tidløs definisjon på en datamaskin vil jeg prøvd meg på noe følgende: *En datamaskin er en maskin (elektronisk, mekanisk, biologisk el.) som tar inn en form for data, prosesserer denne og gir ut behandlede data..* Ordbøker definerer uttrykket på følgende måte: *Websters comput'er - also called processor: Electronic device designed to accept data, perform prescribed mathematical and logical operations at high speed, and display the result of these operations Oxford computer - An electronic machine that can store, organize and find information, do calculations and control other machines.*

I løpet av det siste tiåret har det vært stor vekst innenfor en spesiell type datamaskiner, nemlig innebygde (embedded) systemer. Dette er gjerne små datamaskiner, typisk på en brikke, som gjerne er spesialdesignet til å utføre en spesiell oppgave. Typiske eksempler på innebygde systemer er mobiltelefoner, mp3spillere og digitale planleggere.

I dette faget er arkitekturen og virkemåten til en vanlig PC et sentralt tema. Denne virkemåten er veldig lik det som vi finner i andre systemer, men kan variere litt i kompleksitet. Over kan du se en oversikt over hvordan en von Neumann Maskin er bygd opp. Den består av fire deler:

- Primærminne, som inneholder data og instruksjoner (program)
- En aritmetisk og logisk enhet (eng:ALU) som utfører selve beregningene
- En kontrollenhet som tolker instruksjonene og sørger for at de blir utført
- Inn og ut data enheter, som f.eks. kan lagre data over lengre tid slik som eksterntminnet.




Figur 4.1: Oversikt over en datamaskin

4.2 Hovedkort


Hvis du åpner opp kabinettet på en vanlig PC, dvs. den boksen som er selve datamaskinen, finner du hovedkortet. Figur 4.2 og 4.3 viser et typisk hovedkort hvor sentrale komponenter er navngitte.

Hovedkomponenter

- Prozessorsokkelen er av typen socket A. Prosessoren er ikke koblet til på bildet over.
- Primærlager kan kobles til DIMM-soklene (DIMM er en standard for tilkobling av RAM) som er merket «minnesokler».
- BIOS (Basic Input/Output System) er (for vanlige PC-er) navnet på et program som ligger i ROM (evt. flash). En av BIOS-ens viktigste oppgaver er å sørge for å hente operativsystemet fra sekundærlageret.
- Strøm: Her kobles strømmen til hovedkortet. Eksterne enheter og sekundærlageret har egen strømtilkobling.
- Kontakter: Her er et grensesnitt for eksterne komponenter slik som tastatur og printer.
- ATA, Floppy: Her kan man koble til sekundærlager (harddisk, cd-rom). Kontakten øverst til venstre kan du koble til diskettstasjonen. De resterende kontaktene i denne ruten er IDE-kontakter til sekundærlageret. Grunnen til at det er 4 tilkoblinger i motsetning til 2 som er normalt er for at dette spesielle hovedkortet inneholder en RAID-kontroller. Nyere hovedkort har



Figur 4.2: Hovedkort, komponenter



Figur 4.3: Hovedkort, tilkoblinger

en mulighet for tilkobling av serial-ATA som er en ny seriell utgave av ATA.

- Busser: Her kan ekspansjonskort som nettverkskort, grafikkort og lydkort tilkobles. Det brune tilkoblingspunktet helt til venstre er en AGP slot som er laget for grafikkort. De hvite tilkoblingspunktene til høyre er PCI-slottet som er standarden for de fleste ekspansjonskortene i stasjonære PC-er.

Kapittel 5

Instruksjoner

5.1 Instruksjonssett

En datamaskins oppførsel bestemmes av instruksjonene den utfører. En instruksjon er en konkret og ofte elementær oppgave som prosessoren kan utføre. Mange slike elementære instruksjoner settes sammen til et større program.

Samlingen med instruksjoner en gitt prosessor kan utføre kalles prosessorens *instruksjonssett*. Hvilke instruksjoner som bør være med i en prosessors instruksjonssett har vært gjenstand for mye forskning, og problemet har fremdeles ingen entydig løsning. Over er det vist et eksempel på instruksjoner man kan sette opp.

Viktige egenskaper ved forskjellige instruksjonssett:

- Operasjoner: Hvilke og hvor komplekse operasjoner det finnes instruksjoner til.
- Datatyper: Hvilke datatyper prosessoren kan håndtere direkte
- Hvilket instruksjonsformat instruksjonene bruker, dvs. hvordan instruksjoner kodes i et instruksjonsord
- Hvor mange registre prosessoren støtter
- Hvordan prosessoren angir operandene; hvordan operanddata adresseres

5.1.1 Instruksjonstyper

Alle instruksjoner kan grovt plasseres i én av disse gruppene:

- *Dataoverføring*: Instruksjoner som overfører data fra én spesifisert plass til en annen. Dette kan for eksempel være mellom to registre eller mellom to RAM-celler.
- *Aritmetikk*: Instruksjoner som gjør enkle aritmetiske operasjoner, for eksempel addisjon, subtraksjon, multiplikasjon, divisjon.
- *Logisk*: Instruksjoner som gjør logiske operasjoner. Disse arbeider ofte på et helt dataord av gangen og gjør den logiske operasjonen på alle bitene i dataordet. Eksempler: AND, OR, NOT, XOR, diverse skiftoperasjoner

- *Konvertering*: Konvertering mellom forskjellige datatyper, f.eks fra desimaltall (BCD) til binær.
- *I/O*: Instruksjoner for kommunikasjon med I/O-enheter.
- *Systemkontroll*: Instruksjoner som krever spesielle systemprivilegier for å bli utført. Disse blir som oftest bare utført av operativsystemet; vanlige brukerprogrammer vil ikke ha mulighet til å utføre disse. Eksempler kan være endring av konfigurering av virtuelt lager, endring av kontrollregistre etc.
- *Kontrollflyt*: Instruksjoner som endrer flyten av instruksjoner gjennom prosessoren. Vanligvis utføres instruksjoner én etter én sekvensielt slik de er lagret i RAM. Kontrollflytinstruksjoner medfører hopp i programmet. Dette er helt nødvendig for å kunne lage programløkker og for å lage betinget kode, dvs. kode som kun utføres dersom en betingelse er oppfylt.

De vanligste kontrollflytinstruksjoner er hopp (branch) og prosedyrekall:

- Hoppinstruksjoner kan være ubetinget eller betinget. Betingete hoppinstruksjoner utfører hoppet hvis og bare hvis en gitt betingelse er oppfylt. Dette brukes til å implementere bl.a if-setninger i høynivåspråk.
- Prosedyrekall krever egne hoppinstruksjoner. En prosedyre er et delprogram som kan kalles hvor som helst i hovedprogrammet. Etter at prosedyren har kjørt seg ferdig hopper prosessoren tilbake til stedet i hovedprogrammet der prosedyren ble kalt. Prosessoren må altså huske hvor kallet til prosedyren ble utført (returadressen) for å kunne hoppe tilbake dit etter at prosedyren har kjørt seg ferdig. Returadressen kan enten lagres på en stakk eller i et spesielt returregister.

5.2 Representasjon

5.2.1 Maskinspråk

Som alt annet i en datamaskin så lagres instruksjoner som lange remser med tall. Dette kan for eksempel se slik ut:

```
EE000000
EE050005
A3000503
B7000000
A4111110
```

Det er nesten umulig for mennesker å programmere et slikt rent maskinspråk direkte. Derfor kom det tidlig oversettere fra tekstlige programbeskrivelser til maskinspråk.

5.2.2 Assemblyspråk

For å gjøre det lettere for mennesker å håndtere maskinspråk ble assembleren oppfunnet. Hver instruksjon fikk et huskesymbol (eng: mnemonic); et lite navn. Når man skal programmere kan man skrive slike navn i stedet for å skrive inn

instruksjonsnumrene direkte. Assembleren tar seg av å oversette fra den tekstlige beskrivelsen til tall. Dette er en direkte oversetting; hver linje tilsvarer én gitt instruksjon, og hver prosessortype har derfor sitt eget assemblyspråk.

Etter hvert har assemblerne fått flere utvidelser. Man kan skrive kommentarer etter hver instruksjon for å forklare hva den gjør. Man kan bruke merkelapper (labels) i stedet for å angi absolutte adresser (for eksempel ved hopp), noe som gjør at man slipper å holde styr på adressene selv. Man har også fått makromuligheter (gruppere flere instruksjoner sammen til en makro-instruksjon) og betinget assemblering (assembleren bruker bare deler av koden, avhengig av parametere).

Et eksempel på assemblerkode:

```
        load $0, 0          ; legg verdien 0 i register 0
        load $5, 5          ; legg verdien 5 i register 5
loop    ; merkelapp
        jge $0, $5, slutt   ; hopp til slutt hvis register 0 er
        ;   større eller lik register 5
        inc $0              ; inkremerer register 0
        jmp loop            ; hopp tilbake til merkelapp
slutt
```

Denne koden teller opp register 0 fra 0 til 5. En assembler vil oversette dette til maskinkode bestående av tall. Både assemblerkode og tilhørende maskinkode vil variere fra prosessor til prosessor.

Assemblerkoden ser kanskje kryptisk ut for et utrenet øye, men det burde ikke være tvil om at den er enklere å håndtere enn maskinkoden.

5.2.3 Høynivåspråk

Assemblyspråk er som sagt en direkte overgang fra en tekstlig beskrivelse til maskininstruksjoner. Også dette ble etter hvert for detaljert, og man begynte å utvikle høynivåspråk. Dette er programmeringsspråk der man ikke har en direkte sammenheng mellom høynivåkoden og den underliggende maskinkoden. Høynivåkoden gir som oftest muligheter til å skrive inn komplekse uttrykk på en enkel måte uten å ta hensyn til hvilke muligheter prosessoren i bunnen gir. En kompilator oversetter høynivåkoden til maskinkode (ofte med assemblyspråk som mellomledd).

Et C-program som gjør det samme som assemblerkoden over kan se slik ut:

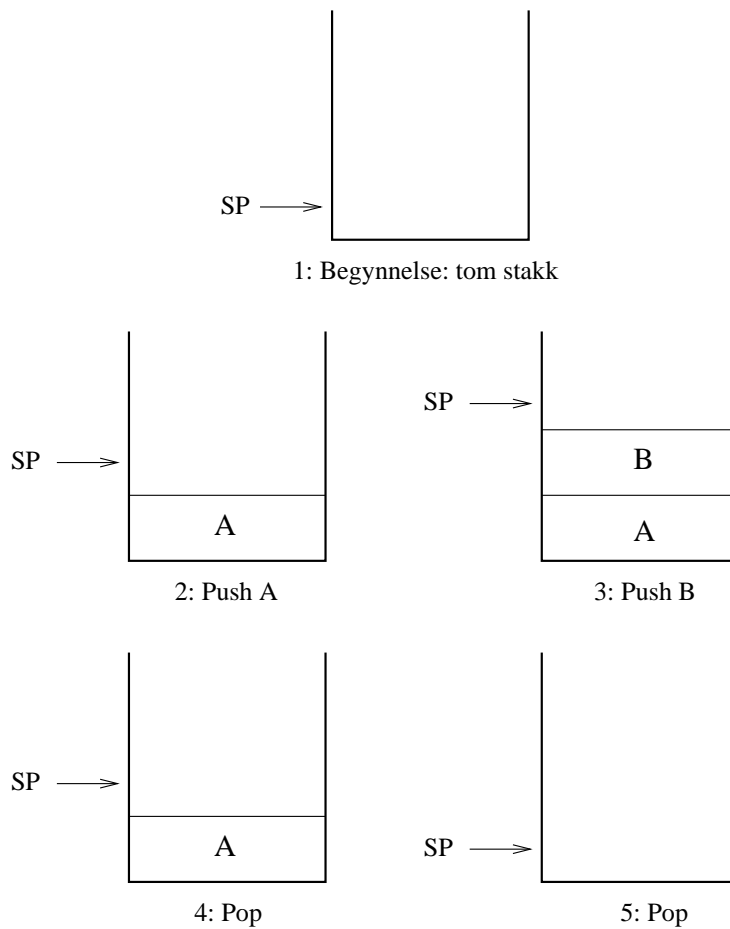
```
i = 0;

while (i < 5) {
    i++;
}
```

5.3 Stakk

En stakk er en sentral datastruktur for prosessorer; de fleste prosessorer benytter en stakk på en eller annen måte.

En stakk kan sammenlignes med en bunke papir der du bare har lov til å legge til eller hente ut papir fra toppen av bunken. Dette blir altså en Last-In-First-Out (LIFO) datastruktur: Det siste elementet som ble lagt til stakken er det elementet som hentes ut.



Figur 5.1: Stakkeksempel

Stakken består av et lager og en stakkpeker (SP). Siden stakken endrer størrelse brukes stakkpekeren til å vise hvor i lageret toppen av stakken befinner seg for øyeblikket. Stakkpeker peker på neste ledige element i lageret.

De fundamentale stakkoperasjonene er PUSH og POP:

- PUSH legger til et dataelement til toppen av stakken og øker stakkpeker med én.
- POP henter ut data fra toppen av stakken og minsker stakkpeker med én.

5.3.1 Eksempel

Et eksempel er vist i figur 5.1. To verdier legges på en tom stakk og hentes deretter ut igjen:

- Begynner med tom stakk
- PUSH A; A legges på stakken

- PUSH B; B legges på stakken
- POP; B hentes ut fra stakken
- POP; A hentes ut fra stakken

Som vist, hentes elementer ut fra stakken i motsatt rekkefølge.

5.4 Antall operander

Instruksjoner tar ofte operander (argumenter).

Som et eksempel, se på følgende operasjon:

```
D \regassignment A + B
```

Her skal A legges sammen med B. Svaret skal legges i D. En instruksjon som implementerer denne operasjonen må altså vite hvilke tre dataverdier den skal jobbe på (A, B og D).

Instruksjoner kan klassifiseres etter hvor mange eksplisitte operander de tar.

5.4.1 Ingen operander

Instruksjonen har ingen eksplisitte operander. Instruksjonen som gjør operasjonen vist over vil derfor se slik ut:

```
ADD
```

En prosessor med overvekt av slike 0-operand-instruksjoner kalles «stakkmaskin». Prosessoren trenger ikke mer informasjon om denne instruksjonen fordi den vet at den skal hente A og B fra en stakk, og svaret skal legges på toppen av stakken. For å utføre $D \leftarrow A + B$, kan man utføre følgende stakkmaskinprogram:

```
PUSH A ; legg A på toppen av stakken
PUSH B ; legg B på toppen av stakken
ADD    ; fjern de to øverste tallene på stakken,
        ; legg de sammen og legg svaret på toppen av stakken
```

Svaret vil nå ligge på toppen av stakken.

5.4.2 Én operand


Instruksjonen kan ha maksimalt én eksplisitt operand, og har dermed to implisitte.

```
ADD B
```

Prosesorer med overvekt av slike instruksjoner kalles ofte for en «akkumulatormaskin» og er en prosessorarkitektur som var mye brukt på 60 og 70-tallet. Prosessoren har et spesielt register som kalles en akkumulator som automatisk tar opp rollen til to av operandene. Instruksjonen over vil gjøre følgende: Akkumulator \leftarrow Akkumulator + B. For å utføre operasjonen $D \leftarrow A + B$, må man gjøre følgende:

```
LDA A ; legg A i akkumulatoren
ADD B ; Legg sammen akkumulator og B
```

Svaret vil nå ligge i akkumulatoren



Figur 5.2: Skal man kappe egget i den store eller lille enden?

5.4.3 To operander

Instruksjonen har maksimalt to eksplisitte operander.

```
ADD A, B
```

Her vil destinasjonen være implisitt. Instruksjonen vil utføre følgende operasjon: $A \leftarrow A + B$. Svaret vil altså ligge der A-operanden lå.

5.4.4 Tre operander

Alle operander er eksplisitte.

```
ADD D, A, B
```

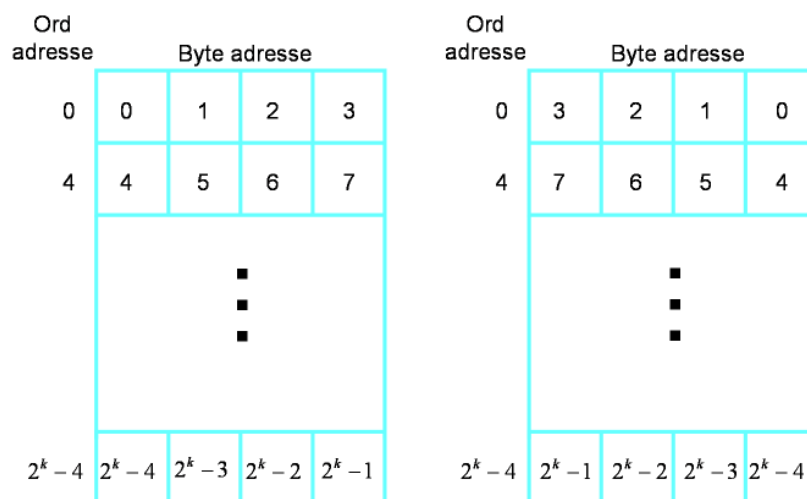
Prosessoren trenger ikke ta noen implisitte avgjørelser, all informasjon er gitt av instruksjonen.

5.5 Big/Little/Bi endian

De fleste datamaskiner opererer med byte som minste adresserbare enhet. Prosessorer klarer likevel å behandle større dataenheter, f.eks. 16 bit, og må ha en standard for hvordan disse 16 bitene skal splittes opp og legges inn i et byteadressert lager.

Figur 5.3 viser de to ulike måtene man kan representere byteadresser på i prosessoren. Den første metoden (til venstre i Figur 5.3), der mest signifikante byte legges på laveste adresse, kalles *big endian* (brukt bl.a. av prosessorene Motorola 680x0 og SPARC). Den andre metoden (til høyre i Figur 5.3), der mest signifikante byte legges på høyeste adresse, kalles *little endian* (brukt bl.a. av Intel x86).

Begge deler er like vanlige, noe som er et klassisk problem i systemer som benytter flere forskjellige typer prosessorer (f.eks. datautveksling mellom Intel-prosessorer og Motorola-prosessorer). På grunn av dette finnes det *bi-endian* prosessorer, dvs. prosessorer som kan bruke begge metodene (f.eks. PowerPC).



Figur 5.3: Big endian og Littel endian



Figur 5.4: Instruksjonsord


5.6 Instruksjonsformat

Instruksjoner består av en mengde bit, satt sammen til et instruksjonsord. Instruksjonsordet kan ha en fast lengde, eller det kan variere fra instruksjon til instruksjon. Lengden på instruksjonsordet har betydning for hvor mye informasjon man kan legge inn i instruksjonen. Ofte vil man likevel ha det så kort som mulig for å bruke minst mulig plass. En løsning kan være variabel lengde på instruksjonene, men det medfører en mer kompleks prosessor.


For at prosessoren skal kunne kjenne igjen og forstå instruksjoner må disse angis på et fast bestemt format. En instruksjon må inneholde informasjon om hva som skal utføres og på hvilke data den skal utføres på. Instruksjonsordet deles inn i felter, som hver er på en eller flere bit. Måten instruksjonsordet deles inn i felter på kalles instruksjonens *instruksjonsformat*.

Hver instruksjon må inneholde et felt kalt *opkode* som forteller prosessoren hvilken type instruksjon det er snakk om. I tillegg må instruksjonen inneholde felter som beskriver tilleggsinformasjon som trengs under utføring av instruksjonen (bl.a operandene). Se figur 5.4.

Opkoden forteller entydig hva denne instruksjonen skal gjøre og hvordan resten av instruksjonsordet skal tolkes. Det finnes ofte flere instruksjonsformat for en og samme prosessor, og opkoden brukes derfor til å finne ut hvilket format den aktuelle instruksjonen har. Instruksjonsformater for ALU-operasjoner har ofte felter for to kildeoperander og destinasjon, mens en kontrollflytinstruksjon (f.eks. hoppinstruksjon) har felt med referanse til neste instruksjon.



Figur 5.5: MIPS rformat



Figur 5.6: MIPS add

5.6.1 Eksempel

Som et eksempel vises en ADD instruksjon fra MIPS-prosessoren. Alle MIPS-instruksjoner er på 32-bit, og den har svært få forskjellige instruksjonsformater. Opkoden er alltid de 6 mest signifikante bitene. Instruksjonsformatet som benyttes til de fleste instruksjoner ser ut som i figur 5.5.

Vi skal sette opp instruksjonsordet til følgende instruksjon:

ADD \$3, \$1, \$2

Legg sammen register 1 og 2. Legg resultatet i register 3.

Feltene i instruksjonsordet over vil settes slik:

- Opkoden vil være 0. Dette spesifiserer hvilket instruksjonsformat, og at dette er en ALU-operasjon.
- rs er kilderegister én, og settes til 1
- rt er kilderegister to, og settes til 2
- rd er destinasjonsregister og settes til 3
- shamt brukes ikke i denne instruksjonen, settes til 0
- funct settes til 32, som betyr addisjon

Da ender vi opp med et instruksjonsord som ser slik ut:


Som binær: 00000000 00100010 00011000 00100000

Som heksadesimal: 00221820


5.7 Adresseringsmodi

En instruksjon er ofte avhengig av operander for å kunne utføres. Et eksempel er en instruksjon som gjør dette: $D \leftarrow A + B$. En slik instruksjon må inneholde en referanse til hvor A og B skal hentes fra, og hvor resultatet D skal lagres. Måten instruksjonen angir hvor data skal hentes fra kalles en adresseringsmodus. Følgende adresseringsmoduser er vanlige:

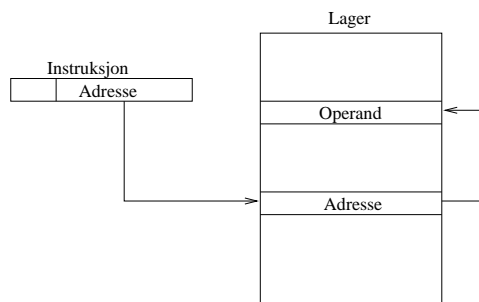
- Immediate: Operanden er innbakt i instruksjonen. Dersom operanden er kjent (en konstant) når programmet lages, kan verdien av denne legges inn i selve instruksjonen.
- Direkte: Instruksjonen angir adressen til operand i RAM.




Figur 5.7: Immediate



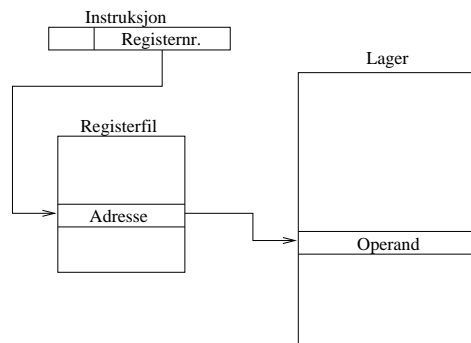
Figur 5.8: Direkte



Figur 5.9: Indirekte



Figur 5.10: Register



Figur 5.11: Indirekte register

- Indirekte: Instruksjonen angir adresse til RAM-celle som igjen inneholder adressen til operand
- Register: Instruksjon har nummer på register som inneholder operand
- Indirekte register: Instruksjon har nummer på register som inneholder adresse til operand i RAM

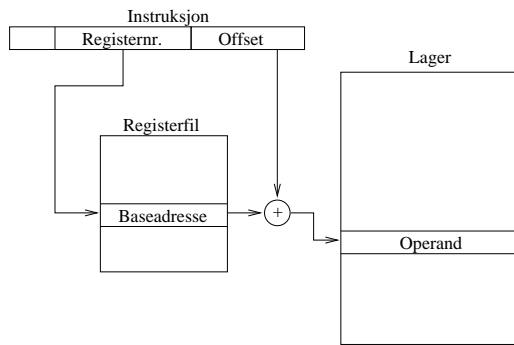
- Displacement: Instruksjon har nummer på register som inneholder base-adresse som adderes med en konstant angitt i instruksjon. Vi har altså en konstant (offset i figuren) som blir lagt til innholdet i et register.

Dette er veldig nyttig, f.eks til tabelloppslag der man har baseadressen til tabellen i et register og man skal ha det n-te elementet i tabellen.

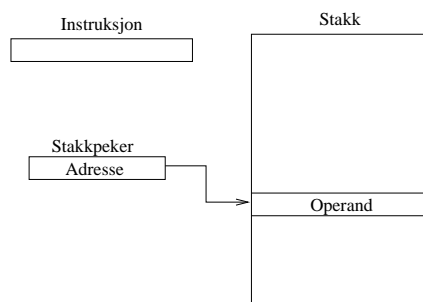
Dersom konstanten benyttes som baseadresse og registeret inneholder «offset»-en, kalles denne metoden for indeksering.

Dette er egentlig det generelle tilfellet av *relativ adressering* som brukes til hoppinstruksjoner der man hopper et gitt antall bytes relativt til programtelleren. Da vil programtelleren være implisitt gitt, og «offset» gis direkte i instruksjonen.

- Stakk: Adressen er implisitt gitt av stakkpeker.



Figur 5.12: Displacement



Figur 5.13: Stakk

Kapittel 6

Assemblyprogrammering

6.1 Hvordan programmere assemblerspråk

Å skrive programmer på assembler-nivå kan virke tungvint og vanskelig for mange som er vant til høynivåspråk som C og Java.

Ofte kan det være lurt å først skrive ned algoritmen man skal implementere i (java liknende) pseudokode for deretter å «kompilere» denne ned til assemblerspråk for hånd.

Dette rommet tar for seg en del vanlige kontrollstrukturer i høynivåspråk og viser hvordan disse kan oversettes til assemblerspråk for load/store-arkitekturen til Dark.

6.1.1 if, else if, else

Dette er kanskje den viktigste kontrollstrukturen. Man vil garantert få bruk for noe som ligner på dette når man programmerer.

Først viser vi et eksempel på bruk av if-else i pseudokode:

```
if ( a < b ) {
  d = a;
} else if ( b > c ) {
  d = b;
} else {
  d = c;
}
```

Dette kan oversettes til assemblerspråk slik:

```
; $1 : a
; $2 : b
; $3 : c
; $4 : d

                jge $1, $2, ifa          ; if( a < b ) {
                add $4, $1, zero         ;     d = a;
                jmp ifend                ; }
                ;
ifa:            jle $2, $3, ifb          ; else if( b > c ) {
                add $4, $2, zero         ;     d = b;
                jmp ifend                ; }
```

```

ifb:          ; else {
            add $4, $3, zero      ; d = c;
            ; }
ifend:

```

Vi ser at en if-setning består av et betinget hopp som hopper til neste else dersom if-betingelsen *ikke* er oppfylt (betingelsen til hoppinstruksjonen er derfor den motsatte av if-betingelsen i pseudokoden). Dersom betingelsen *er* oppfylt utføres det som står inne i if-blokken ($d = a$) og det gjøres et hopp til slutten av if-setningen (ifend).

Else-if implementeres på akkurat samme måte.

Else-setningen har ingen betingelse og vil derfor alltid utføre dersom vi kommer til dette punktet i programmet.

6.1.2 while

While er en vanlig måte å lage løkker på. Vi har en betingelse som sjekkes for hver iterasjon i løkken. Dersom den *ikke* er oppfylt hopper vi ut av løkken.

```

while (a < b) {
    a++;
}

```

Dette kan implementeres på følgende måte:

```

; $1 : a
; $2 : b

wstart: jge $1, $2, wend      ; while( a < b ) {
            inc $1              ; a++;
            jmp wstart          ; }
wend:

```

Vi har et betinget hopp som hopper ut av løkken dersom betingelsen ikke er oppfylt. Hvis ikke utføres løkken og vi har på bunnen en hoppinstruksjon som hopper tilbake til toppen av løkken.

6.1.3 do while

Do-while er nesten lik while bortsett fra at betingelsen sjekkes på slutten av hver iterasjon i stedet for på begynnelsen. Denne benyttes mye sjeldnere enn while i språk som C og java.

```

do {
    a++;
} while (a < b);

```

Dette kan implementeres slik:

```

; $1 : a
; $2 : b

loop:      ; do {
            inc $1              ; a++;
            ;
            jle $1, $2, loop    ; } while (a < b);

```

Vi har her ikke noe betinget hopp på toppen av løkken, vi har i stedet satt betingelsen på hoppinstruksjonen på bunnen. Dette er egentlig mer intuitivt enn vanlig while i assemblerspråk. Vi får en hoppinstruksjon mindre noe som både er mer effektivt og oversiktlig.

6.1.4 for

For-løkker er veldig vanlig og nyttig. For-løkker i C og java er veldig generelle, men vi har vanligvis en teller som begynner på en startverdi og teller opp til vi når en sluttverdi. Og for hver gang vi teller opp telleren utføres løkka en gang.

```
for (i = 0; i < a; i++) {
    b++;
}
```

Dette kan implementeres slik:

```
; $1 : i
; $2 : a
; $3 : b

      mov $1, 0          ; for(i = 0; i < a; i++) {
floop: jge $1, $2, fend   ;
      inc $3             ;     b++;
      inc $1             ;
      jmp floop          ; }
fend:
```

Vi må først sette tellerregisteret vårt til 0. Deretter starter løkken. På toppen av løkken finnes et betinget hopp som hopper ut av løkken hvis betingelsen ikke er oppfylt. Innholdet i løkken utføres, tellerregisteret inkrementeres og vi hopper tilbake til toppen av løkken igjen.

6.1.5 prosedyrer

Prosedyre kall er veldig nyttig når vi ønsker å utføre den samme kodebiten flere steder i programkoden. I C kalles prosedyrene for *funksjoner*, i java kalles de ofte for *metoder*.

Det finnes svært mange måter å implementere prosedyrer på i assembler-språk. Hovedsaklig består de av en kodebit som ender med instruksjonen `ret`. Prosedyren kalles med instruksjonen `call`. Problemet består i hvordan man overbringer argumenter og returverdier.

Her er et eksempel:

```
int main() {

    int a = 10;
    int b = 2;
    int c = 5;

    c = addisjon(a,b) + subtraksjon(b,c);
}

int addisjon(int a, b) {
    return a+b;
}
```

```

}

int subtraksjon(int a, b) {
    return a-b;
}

```

Dette kan vi på en enkel måte oversette slik:

```

; $1 : a
; $2 : b
; $3 : c
; $4 : arg a til add
; $5 : arg b til add
; $6 : returverdi fra add
; $7 : arg a til sub
; $8 : arg b til sub
; $9 : returverdi fra sub

        load $1, 10
        load $2, 2
        load $3, 5

        add $4, $1, 0
        add $5, $2, 0
        call add

        add $7, $2, 0
        add $8, $3, 0
        call sub

        add $3, $6, $9

;-----

add:    add $6, $4, $5
        ret

sub:    sub $9, $7, $8
        ret

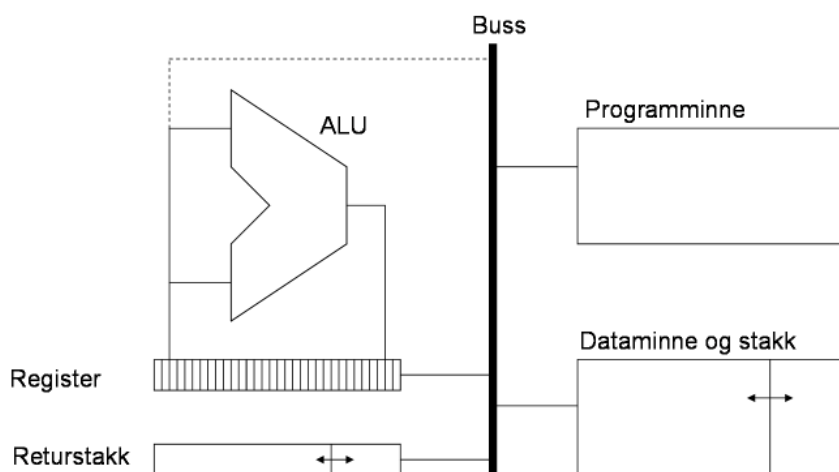
```

Vi ser at hver prosedyre har fått allokert et sett med registre som benyttes til argumenter og returverdi. Dette er enkelt og raskt, men har mange problemer. Hver gang vi kalles en prosedyre vil noen av registrene få slettet sin verdi. Dessuten vil vi få problemer med nøstede prosedyrekall og rekursjon.

Løsningen er ofte å bruke en stakk. Før prosedyren kalles kan man lagre alle registre på stakken. Da kan man etter at prosedyren er ferdig gjenopprette disse. Argumenter og returverdier lagres også på stakken. Det samme gjør vi med eventuelle lokale variable som ikke får plass i registre. Dette gjør at vi ikke får noen problemer med rekursjon og nøstede kall.

6.2 Dark load-store-maskin

Dette dokumentet beskriver arkitekturen til load-store-maskina som benyttes i Dark. Figur 6.1 viser hvordan den ser ut. Det finnes 32 registre i maskinen. I alle instruksjoner som jobber med data må minst en av operandene være et register og resultatet blir satt inn i et av registrene. Tre av registrene har spesielle anvendelsesområder og bør anvendes forsiktig:



Figur 6.1: Load-store arkitektur i Dark

- Register 0 (null) har alltid verdien null og kan ikke endres
- Register 1 (en, «zero») er reservert for assembleren
- Register 31 (brukes til «sp») brukes til stakkpekeren og peker alltid på nåværende stakktopp i nåværende stakk.

6.2.1 Syntaksdefinisjon

- Noe som er skrevet i *courier* er et nøkkelord som må være med.
- Noe som er skrevet i SMALL CAPS er et ord eller uttrykk som må settes, men programmereren kan selv bestemme den rette verdien f.eks. variabelnavn. Variabelnavnet kan ikke være det samme som et av nøkkelordene.
- Noe som er skrevet i *kursiv* er noe som eventuelt kan forekomme
- Noe som er skrevet i normal stil i semantiskbeskrivelse er en oppdatering av et internt (usynlig) register.
- {a|b} betyr enten a eller b.
- NUMMER er hvilket som helst nummer.
- VARIABEL er hvilken som helst variabel.
- Om en stakk(f.eks. returstakk) står på venster side av en ← betyr det at verdien legges på stakken. Om den står til høyre for pilen betyr det at verdien hentes fra toppen av stakken og tas bort.

6.2.2 Symbolske adresser

Syntaks:

ETIKETT

Semantikk:

ETIKETT \leftarrow minneposisjon

Lag en LABEL som viser hvor i minne et gitt kodelykke begynner. Disse LABEL-ene kan man skrive hvor som helst foruten inne i instruksjonene, f.eks. så går det fint å skrive snurra ret.

6.2.3 Register

\$

Syntaks:

\$NUMMER

Sifferne angir hvilket register man bruker.

sp

Syntaks

sp

Angir at man vil bruke register 31.

zero

Syntaks

zero

Angir at man vil bruke register 0.

6.2.4 Variabeldefinisjoner

data

Syntaks:

data *nummer* NAVN

Om et nummer er gitt kommer variabelen ha denne verdien i begynnelsen av eksekveringen av programmet, ellers så er ikke verdien definert.

6.2.5 Kommentarer

Syntaks

; *tekst*

All tekst som står etter et semikolon(;) blir tolket som kommentarer

6.2.6 Instruksjonsoppsett

add

Syntaks

add REGISTER,REGISTER,{REGISTER|NUMMER|VARIABEL}

Semantikk

register \leftarrow register + {register|NUMMER|VARIABEL}

Målregisteret får summen av andre og siste verdi.

and

Syntaks

and REGISTER,REGISTER,{REGISTER|NUMMER|VARIABEL}

Semantikk

register \leftarrow register \wedge {register|NUMMER|VARIABEL}

Målregisteret får verdien til den logiske AND-en mellom andre og siste verdi

band

Syntaks

band REGISTER,REGISTER,{REGISTER| NUMMER|VARIABEL}

Semantikk

register \leftarrow register \wedge {register|NUMMER|VARIABEL}

Målregisteret får verdien til den bitvise logiske AND-en mellom andre og siste verdi.

bnot

Syntaks

bnot REGISTER,REGISTER

Semantikk register \leftarrow \neg register

Den bitvise logiske NOT av register to legges inn i målregisteret.

bor

Syntaks

bor REGISTER,REGISTER,{REGISTER|NUMMER|VARIABEL}

Semantikk

register \leftarrow register \vee {register|NUMMER| VARIABEL}

Målregisteret får verdien til den bitvise logiske OR-en mellom andre og siste verdi.

bxor

Syntaks

bxor REGISTER,REGISTER,{REGISTER|NUMMER|VARIABEL}

Semantikk

register \leftarrow register \oplus {register|NUMMER|VARIABEL}

Målregisteret får verdien til den bitvise logiske XOR-en mellom andre og siste verdi.

call

Syntaks

call ETIKETT

Semantikk

returstakk \leftarrow pc

pc \leftarrow ETIKETT

Legger adressen til nåværende instruksjon på retrustakken og hopper til neste instruksjon som ETIKETT peker på.

dec

Syntaks

dec REGISTER

Semantikk

register \leftarrow register -1

Målregisteret blir dekrementert(minsket) med 1.

div

Syntaks:

div REGISTER,REGISTER,{REGISTER|NUMMER|VARIABEL}

Semantikk:

register \leftarrow register / {register|NUMMER|VARIABEL}

Målregisteret får svaret av divideringen mellom andre og siste verdi.

end

Syntaks

end |ETIKETT

Semantikk

pc \leftarrow ETIKETT

Slutt på kildekodefilen. Om ETIKETT er gitt skal prosessoren begynne å eksekvere på denne instruksjonen, ellers starter prosessoren med den absolutt første instruksjonen.

inc

Syntaks

inc REGISTER

Semantikk

register \leftarrow register $+1$

Målregisteret blir inkrementert(øker) med 1.

jeq

Syntaks:

jeq REGISTER,REGISTER,ETIKETT

Semantikk:

{|pc \leftarrow ETIKETT}

Om verdiene i registrene er like hopper programmet til den symbolske adresse ETIKETT, eller skjer det ingenting.

jge

Syntaks:

jge REGISTER,REGISTER,ETIKETT

Semantikk: $\{\text{pc} \leftarrow \text{ETIKETT}\}$

Om verdien i det første registeret er større eller lik verdien i det andre registeret så hopper programmet til ETIKETT, eller skjer det ingenting.

jgt**Syntaks:** $\text{jgt REGISTER,REGISTER,ETIKETT}$ **Semantikk:** $\{\text{pc} \leftarrow \text{ETIKETT}\}$

Om verdien i det første registeret er større en verdien i det andre registeret hopper programmet til ETIKETT, eller skjer det ingenting.

jle**Syntaks:** $\text{jle REGISTER,REGISTER,ETIKETT}$ **Semantikk:** $\{\text{pc} \leftarrow \text{ETIKETT}\}$

Om verdien i det første registeret er mindre eller lik verdien i det andre registeret hopper programmet til ETIKETT, ellers skjer ingenting.

jlt**Syntaks:** $\text{jlt REGISTER,REGISTER,ETIKETT}$ **Semantikk:** $\{\text{pc} \leftarrow \text{ETIKETT}\}$

Om verdien i det første registeret er mindre en verdien i det andre registeret hopper programmet til ETIKETT, ellers skjer ingenting.

jmp**Syntaks:** jmp ETIKETT **Semantikk:** $\{\text{pc} \leftarrow \text{ETIKETT}\}$

Eksekveringen fortsetter med instruksjonen via ETIKETT

jne**Syntaks:** $\text{jne REGISTER,REGISTER,ETIKETT}$ **Semantikk:** $\{\text{pc} \leftarrow \text{ETIKETT}\}$

Om verdiene i registrene er ulike hopper programmet til ETIKETT, ellers skjer ingenting.

load

Syntaks:

load REGISTER, {REGISTER, NUMMER|NUMMER|VARIABEL}

Semantikk:

register \leftarrow {mem[register+NUM]|NUM|VAR}

Målregisteret får enten verdien som er angitt som et nummer, innholdet i variabelen eller innholdet i minneposisjonen som man finner ut fra registeret + nummeret.

mod

Syntaks:

mod REGISTER, REGISTER, {REGISTER|NUMMER|VARIABEL}

Semantikk:

register \leftarrow register \setminus {register|NUMMER|VARIABEL}

Målregisteret får resten etter divisjon mellom den andre og siste verdien.

mov

Se mv

mul

Syntaks:

mul REGISTER, REGISTER, {REGISTER|NUMMER|VARIABEL}

Semantikk:

register \leftarrow register * {register|NUMMER|VARIABEL}

Målregisteret får produktet av den andre verdien og den siste verdien.

mv

Syntaks:

mov|mv REGISTER, REGISTER

Semantikk:

register \leftarrow register

Verdien av det andre registeret kopieres inn i det første.

not

Syntaks:

not REGISTER, REGISTER

Semantikk:

register \leftarrow \neg register

Logisk NOT av det andre registeret legges i det første.

or

Syntaks:

or REGISTER, REGISTER, {REGISTER|NUMMER|VARIABEL}

Semantikk:

register \leftarrow register \vee {register|NUMMER|VARIABEL}

Målregisteret får verdien til den logiske OR mellom det andre og siste verdiene.

ret

Syntaks:

ret

Semantikk:

pc \leftarrow returstakk

Ekekveringen hopper tilbake fra subrutine.

stop

Syntaks:

stop

Semantikk:

—

Eksekveringen avsluttes.

store

Syntaks:

store REGISTER, {REGISTER|NUMMER|VARIABEL}

Semantikk:

{mem[register+NUMMER]|VARIABEL} \leftarrow register

Registeret lagres i variabelen eller i minneposisjonen som pekes ut av registeret + nummeret.

sub

Syntaks:

sub REGISTER, REGISTER, {REGISTER|NUMMER|VARIABEL}

Semantikk:

register \leftarrow register - {register|NUMMER|VARIABEL}

Målregisteret får differansen av det andre registeret og den siste verdien.

xor

Syntaks:

xor REGISTER, REGISTER, {REGISTER|NUMMER|VARIABEL}

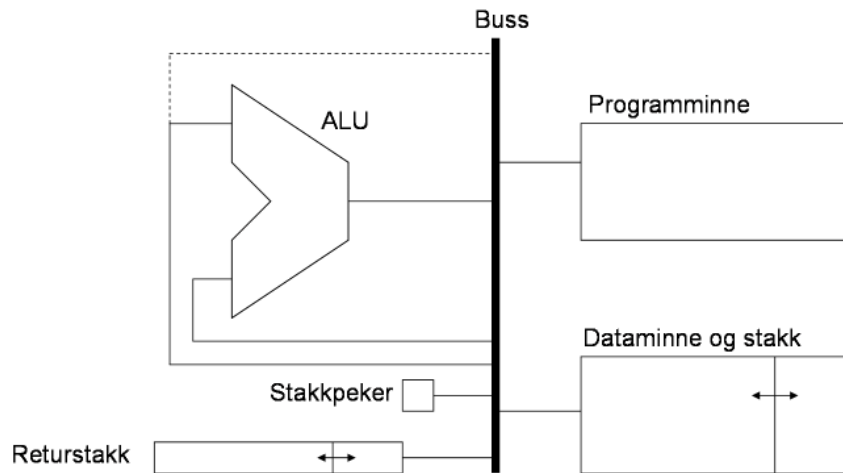
Semantikk:

register \leftarrow register \oplus {register|NUMMER|VARIABEL}

Målregisteret får verdien til XOR-en mellom det andre registeret og den siste verdien.

6.3 Dark Stakkmaskin

Dette dokumentet beskriver arkitekturen til stakkmaskina som benyttes i Dark. Figur 6.2 viser hvordan maskinen ser ut. Det finnes et register i prosessoren, stakkpekeren (sp). Samtlige beregninger bruker det som ligger på stakken og svaret havner alltid på stakken.



Figur 6.2: Stakk arkitektur i Dark

6.3.1 Variabeldefinisjon

area

Syntaks:

`area NUMMER`

Utrykker minneområdet til den siste variabelen med NUMMER posisjoner.

6.3.2 Instruksjonsoppsett

add

Syntaks:

`add`

Semantikk:

$stakk \leftarrow stakk + stakk$

De to øverste verdiene på stakken adresseres og summen av dem blir lagt på stakken. Verdiene som ble addert fjernes fra stakken.

and

Syntaks:

`and`

Semantikk:

$stakk \leftarrow stakk \wedge stakk$

Logisk AND mellom de to øverste verdiene på stakken beregnes og legges på stakken.

band

Syntaks:

band

Semantikk:

stakk \leftarrow stakk \wedge stakk

Bitvis logisk AND av de øverste to verdiene på stakken. Resultatet blir lagt på stakken.

bnot

Syntaks:

bnot

Semantikk:

stakk \leftarrow \neg stakk

Bitvis logiske NOT av den øverste verdien på stakken beregnes og legges på stakken.

bor

Syntaks:

bor

Semantikk:

stakk \leftarrow stakk \vee stakk

Bitvis logisk OR av de øverste verdiene på stakken beregnes. Resultatet legges på stakken.

bxor

Syntaks:

bxor

Semantikk:

stakk \leftarrow stakk \oplus stakk

Bitvis logisk XOR av de to øverste verdiene på stakken beregnes og legges på stakken.

call

Syntaks

call ETIKETT

Semantikk

returstakk \leftarrow pc

pc \leftarrow ETIKETT

Legger adressen til nåværende instruksjon på retrustakken og hopper til neste instruksjon som ETIKETT peker på.

div

Syntaks:

div

Semantikk:

tmp *leftarrow* stakk
stakk \leftarrow stakk / temp

De to øverste verdiene på stakken deles. Resultatet legges på stakken i stedet for de to verdiene.

drop

Syntaks:

drop

Semantikk:

? \leftarrow stakk

Den øverste verdien på stakken tas bort.

dup

Syntaks:

dup

Semantikk:

tmp *leftarrow* stakk

stakk \leftarrow temp

stakk \leftarrow temp

Den øverste verdien på stakken dupliseres.

end

Syntaks

end {|ETIKETT}

Semantikk

pc \leftarrow ETIKETT

Slutt på kildekodefilen. Om ETIKETT er gitt skal prosessoren begynne å eksekvere på denne instruksjonen, ellers starter prosessoren med den absolutt første instruksjonen.

eq

Syntaks:

eq

Semantikk:

stakk \leftarrow stakk = stakk

Om de to øverste verdiene på stakken er like legges det en 1-er på stakken, ellers legges en 0-er.

ge

Syntaks:

ge ETIKETT

Semantikk:

temp \leftarrow stakk

stakk \leftarrow stakk \geq tmp

Om den nest øverste verdien er lik eller større enn den øverste så legger man en 1-er på stakken, ellers legges en 0-er.

gt

Syntaks:

gt

Semantikk:

temp \leftarrow stakk

stakk \leftarrow stakk < tmp

Om den nest øverste verdien er større enn den øverste verdien legges en 1-er på stakken, ellers legges en 0-er.

jfalse

Syntaks:

jfalse ETIKETT

Semantikk:

temp \leftarrow stakk

{|pc \leftarrow ETIKETT}

Om den øverste verdien på stakken er 0 fortsetter eksekveringen med instruksjonen med ETIKETT, ellers skjer ingenting.

jmp

Syntaks:

jmp ETIKETT

Semantikk:

pc \leftarrow ETIKETT

Eksekveringen fortsetter med instruksjoen med ETIKETT

jtrue

Syntaks:

jtrue ETIKETT

Semantikk:

temp \leftarrow stakk

{|pc \leftarrow ETIKETT}

Om den øverste verdien på stakken er ulik null forsetter eksekveringen med instruksjoenen via ETIKETT, eller skjer ingenting.

le

Syntaks:

le

Semantikk:

temp \leftarrow stakk

stakk \leftarrow stakk \leq tmp

Om den nest øverste verdien på stakken er mindre eller lik den øverste verdien en 1-er på stakken, ellers en 0-er.

lt

Syntaks:

lt

Semantikk:

temp \leftarrow stakk
stakk \leftarrow stakk > tmp

Om den nest øverste verdien er mindre en den øverste så legges en 1-er på stakken, ellers legges en 0-er.

mod**Syntaks:**

mod

Semantikk:

temp \leftarrow stakk
stakk \leftarrow stakk \ tmp

De to øverste verdiene på stakken deles og resten av resultatet legges på stakken.

mul**Syntaks:**

mul

Semantikk:

stakk \leftarrow stakk * stakk

De to øverste verdiene på stakken multipliseres og resultatet blir lagt på stakken istedfor de to verdiene.

ne**Syntaks:**

ne

Semantikk:

stakk \leftarrow stakk \neq stakk

Om de to øverste verdiene på stakken er like legges en 0-er på stakken, ellers legges en 1-er.

not**Syntaks:**

not

Semantikk:

stakk \leftarrow \neg stakk

Den logiske NOT av den øverste verdien i stakken beregnes og legges på stakken.

or**Syntaks:**

or

Semantikk:

stakk \leftarrow stakk \vee stakk

Logisk OR mellom de to øverste verdiene på stakken. Resultatet legges på stakken.

pop

Syntaks:

pop VARIABEL

Semantikk:

VARIABEL \leftarrow stakk

Den øverste verdien på stakken legges i VARIABEL

popa

Syntaks:

popa

Semantikk:

temp \leftarrow stakk

mem[temp] \leftarrow stakk

Den øverste verdien på stakken tolkes som en adresse der neste verdi skal lagres.

pull

Syntaks:

pull

Semantikk:

stakk \leftarrow mem[stakk]

Den øverste verdien på stakken tolkes som en adresse. Fra denne adressen hentes en verdi og verdien blir lagt på stakken.

push

Syntaks:

push {NUMMER|VARIABEL}

Semantikk:

stakk \leftarrow {NUMMER|VARIABEL}

Verdien til variabelen/kostnaden legges på stakken.

pusha

Syntaks:

pusha VARIABEL

Semantikk:

stakk \leftarrow &VARIABEL

Adressen til variabelen legges på stakken

ret

Syntaks:

ret

Semantikk:

pc \leftarrow returstakk

Eksekveringen hopper tilbake fra en subrutine.

rot

Syntaks:

rot

Semantikk:

temp1 \leftarrow stakk

temp2 \leftarrow stakk

temp3 \leftarrow stakk

stakk \leftarrow temp1

stakk \leftarrow temp3

stakk \leftarrow temp2

De tre øverste verdiene roteres slik at det som før låg øverst nå ligger nederst.

stop

Syntaks:

stop

Semantikk:

-

Eksekveringen avsluttes

sub

Syntaks:

sub

Semantikk:

tmp \leftarrow stakk

stakk \leftarrow stakk - temp

De to øverste verdiene på stakken blir subtrahert og resultatet legges på stakken i stedet for de to verdiene.

swap

Syntaks:

swap

Semantikk:

temp1 \leftarrow stakk

temp2 \leftarrow stakk

stakk \leftarrow temp1

stakk \leftarrow temp2

De to øverste verdiene bytter plass.

xor


Syntaks:

xor

Semantikk:

stakk \leftarrow stakk \oplus stakk

Logisk XOR av de øverste to verdiene på stakken beregnes og legges på stakken.



Figur 6.3: Darksimulatoren

6.4 Introduksjon til Dark


Dark er en datamaskinarkitektursimulator. Simulatoren lar brukeren skrive inn dataprogrammer på maskinkodenivå og simulere kjøringen av disse med fire forskjellige datamaskinarkitekturer. Dark er tenkt utnyttet i opplæringsøyemed, der brukeren kan anvende simulatoren for å lære om egenskaper ved forskjellige datamaskinarkitekturer.

Dark er utviklet ved Institutionen för Datavetenskap (<http://www.cs.umu.se/>) ved Umeå Universitet av Ola Ågren. Simulatoren har en egen hjemmeside (<http://www.cs.umu.se/~ola/Dark/>) med kildekode, dokumentasjon, artikler om simulatoren og maskinkodeeksempler for hver av arkitekturene.


I AoC blir dere bare testet i to av de fire arkitekturene; Load-Store og stakkarkitektur. Om man går på et spørsmålsikon som inneholder en darkoppgave vil man få opp en oppgaveside og en simulator som vist i figur 6.3.

I editorvinduet legger man inn koden man vil at simulatoren skal teste. I Figur 6.3 er det lagt inn et program som deler to tall på hverandre ved å bruke stakkarkitekturen. Hvilken arkitektur som er valgt kan man se av rullegardinen til venstre under Editoren. Om man ønsker å prøvekjøre programmet trykker man på pars. Når man har trykket på pars vil man få mulighet til å trykke på en av følgende knapper:

- **Step** viser stegvis gangen i koden. Figur 6.4 viser første steg i koden. Stakkvinduet har nå fått tallet 20 i seg, det er fordi man har utført første instruksjon nemlig å legge 20 på stakken. Stakkvinduet vil alltid vise hva som ligger stakken.
- **All steps** viser hva som ligger på stakken når hele programmet er ferdig kjørt. Med dette tilfelle vil det være 2 som ligger på stakken som vist i Figur 6.5
- **Validate** sjekker om koden din gjør det den skal for å løse oppgaven du



Figur 6.4: Step



Figur 6.5: All step

fikk. Om du har svart riktig vil du få melding om det og du får poeng, ellers vil du få beskjed om at den er feil og du må endre koden din ved å trykke på Edit code som vist i Figur 6.5.

Det finnes også to manualer til AoCDarksimulatoren, en for load-store arkitekturen og en for stakk. Begge disse vil man finne underveis i spillet. Disse manualene vil vise hvordan arkitekturen ser ut og hvilke instruksjoner man kan bruke i de ulike arkitekturerne.

Kapittel 7

Prosessorens oppbygning

7.1 Mikrooperasjoner

Før vi går inn på prosessorens oppbygning bør du vite litt om hva en prosessor er i stand til å gjøre for noe. Som et hjelpemiddel til å analysere prosessorens funksjon har vi innført begrepet *mikrooperasjon*.

En mikrooperasjon er en elementær operasjon som blir utført på dataceller. De er som oftest på følgende form: Svarcelle \leftarrow celle1 OP celle2. Man tar to dataelementer (celle1 og celle2), gjør en operasjon på disse, og lagrer svaret i svarcelle. Datacellene er stort sett alltid registre, som du vil lære mer om senere, men kan også være fra datalageret (RAM). Register skrives på denne måten: Rn, hvor n angir hvilket register som benyttes.

Poenget er at vi kan beskrive oppførselen til prosessoren ved hjelp av slike mikrooperasjoner.

De fire vanligste typer mikrooperasjonene er:

- Overføringsmikrooperasjoner overfører data.
- Aritmetiske mikrooperasjoner som utfører aritmetikk.
- Logiske mikrooperasjoner som gjør logiske operasjoner.
- Skift-mikrooperasjoner som forskyver data i registrene.

7.1.1 Aritmetiske mikrooperasjoner

- $R0 \leftarrow R1 + R2$
Innholdet til R1 blir plussset med innholdet til R2 og overført til R0
- $R2 \leftarrow \bar{R2}$
Komplementet av innholdet til R2 (enerkomplement)
- $R2 \leftarrow \bar{R2} + 1$
2-ers komplement av innholdet til R2
- $R0 \leftarrow R1 + \bar{R2} + 1$
R1 pluss 2-ers komplementet til R2 overført til R0 (subtraksjon)

- $R1 \leftarrow R1 + 1$
Inkrementer innholdet til R1 (teller opp)
- $R1 \leftarrow R1 - 1$
Dekrementerer innholdet til R1 (teller ned)

7.1.2 Logiske mikrooperasjoner

- $R0 \leftarrow R1$
Logisk bitvis NOT
- $R0 \leftarrow R1 \text{ AND } R2$
Logisk bitvis AND
- $R0 \leftarrow R1 \text{ OR } R2$
Logisk bitvis OR
- $R0 \leftarrow R1 \text{ XOR } R2$
Logisk bitvis XOR

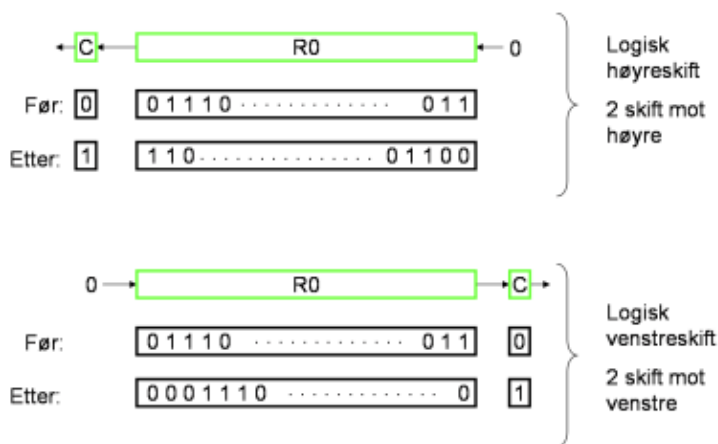
7.1.3 Skift-mikrooperasjoner

Skifter data i et register enten mot høyre eller mot venstre. Venstreskift medfører at alle bit i et binært tall flyttes en plass mot venstre, og minst signifikante bit settes til 0. Dette er ekvivalent med å multiplisere med 2. Høyreskift skifter data mot høyre, som er det samme som å dele med 2.


Vi skiller gjerne mellom logisk skift og aritmetisk skift. Logisk venstreskift er akkurat som forklart over. Logisk høyreskift er tilsvarende, men man skifter alltid inn 0 på mest signifikante bit. Aritmetisk skift brukes når man ønsker å ta vare på fortegnet. Aritmetisk høyreskift er som forklart over, men i stedet for å skifte inn 0 så blir fortegnsbitet (mest signifikante bit) tatt vare på. Tilsvarende for aritmetisk venstreskift; fortegnsbitet blir ikke skiftet vekk.

- $R0 \leftarrow R1 \hat{\ll} R2$
Aritmetisk venstreskift
- $R0 \leftarrow R1 \hat{\gg} R2$
Aritmetisk høyreskift
- $R0 \leftarrow R1 \hat{\ll} \hat{\ll} R2$
Logisk venstreskift
- $R0 \leftarrow R1 \hat{\gg} \hat{\gg} R2$
Logisk høyreskift

Figur 7.1 viser et eksempel på hvordan logisk skift fungerer. I dette eksempelet blir tallet i R0 skiftet to bit enten i høyre eller venstre retning.



Figur 7.1: Eksempel på logiske skift operasjoner



Figur 7.2: Utførende enhet og styreenhet

7.2 Prosessoren

En prosessor er en kompleks enhet i en datamaskin som er i stand til å utføre en algoritme spesifisert ved et lagret program.

En ting du må huske på når du leser om prosessoren, er at det finnes mange måter å lage denne på. Det som presenteres her er én mulig løsning, men andre kilder vil presentere en annen løsning. Det du bør sitte igjen med er en generell forståelse, ikke detaljer om hvordan en spesifikk prosessor fungerer.

Ofte deles prosessorer inn på denne måten:

- Styreenhet (eng: control unit) som styrer den utførende enheten og bestemmer hva som skal utføres
- Utførende enhet (eng: datapath) der data flyter gjennom og blir behandlet

Figur 7.2 viser forholdet mellom utførende enhet og styreenhet. Styreenheten finner ut hva den skal gjøre ved å se på alle sine inngangssignaler. Basert på dette setter styreenheten opp styresignalene som er nødvendig for å få den utførende enheten til å gjøre det den skal. Utførende enhet tar inn data, prosesserer disse (f.eks gjør en logisk operasjon) og sender svaret ut på en utgang. Den forteller også styreenheten enkelte ting den har behov for å vite om resultatet.

7.3 Utførende enhet

Utførende enhet (eng: datapath) er ansvarlig for å prosessere data. En utførende enhet består hovedsaklig av en registerfil og en funksjonell enhet. Figur 7.3 viser et eksempel på en utførende enhet.

En prosessor er en *synkron* enhet. Alt som skjer i prosessoren skjer synkront, dvs. i takt med et klokkesignal. Klokkesignalet veksler mellom verdiene 0 og 1, og en slik veksling kalles en *klokkesyklus*. Alt som skjer innenfor samme klokkesyklus, skjer i parallell.

Registerfilen består av et sett med registre. Et register er et lite og hurtig lager som kan lagre ett ord (ofte 32 bits). Prosessoren har mulighet til å lese ut to registre hver klokkesyklus: A og B. Ved å sette opp registeradresser (registernumrene) på A- og B-adresseinngangene vil de tilsvarende registrene komme ut på datautgangene. Tilsvarende har prosessoren mulighet til å skrive tilbake data til ett register hver klokkesyklus. Dette gjøres ved å sette adressen til registeret det skal skrives til på D-adresseinngangen, og skrive data til D-datainngangen. I tillegg finnes et «write»-signal som indikerer at man ønsker å skrive data til registeret denne klokkesyklusen. I en del prosessorer er ikke register 0 et ekte register. I stedet er det satt konstant lik 0. Dette fordi det ofte er ønskelig å ha en lett måte å få tilgang til denne konstanten på.

Den funksjonelle enheten tar i mot to dataenheter (A og B) og gjør en gitt operasjon på disse. Resultatet sendes ut til en utgang (F). Hvilken operasjon som skal utføres bestemmes av et kontrollsignal merket FS i figuren. Den funksjonelle enheten kan gjøre aritmetiske og logiske operasjoner, f.eks addisjon, subtraksjon, AND og OR. Derfor er det vanlig å kalle denne for en *ALU* (Arithmetic Logic Unit). Det er dette navnet som vil bli brukt senere. En ALU tegnes ofte med symbolet vist i figur 7.4. Dette for å fremheve at en ALU har to hovedinngangssignaler som den behandler, for så å sende resultatet til utgangen.

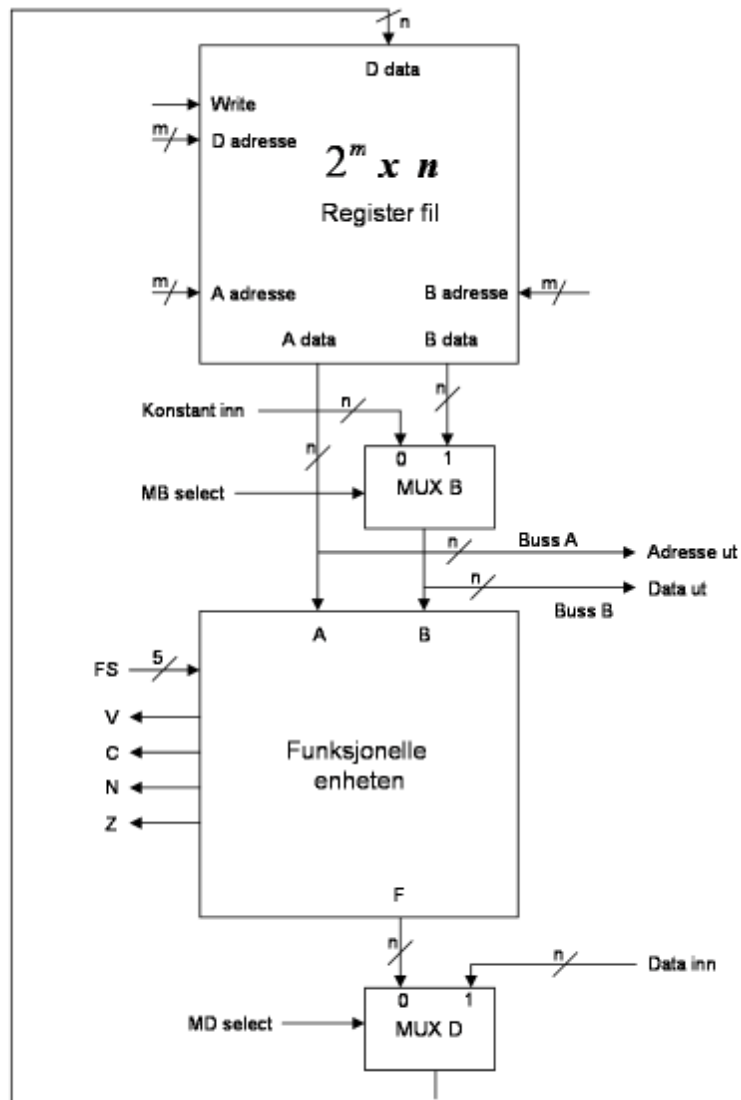
Resultatet av hver ALU-operasjon medfører at visse statussignaler (kalles ofte for *statusflagg*) blir satt. Disse statusflaggene benyttes av styreenheten for å avgjøre hva som skal skje neste sykel.

Vanlige statusflagg er:


- **Mente (C for Carry)**: Forteller at resultatet ble større enn det tilgjengelige antall bit. F.eks med 8-bits tall vil $250 + 10$ «gå rundt», og resultatet blir 4 og C-flagget satt.
- **Overflyt (V)**: Nesten likt C-flagget, men for tall med fortegn. F.eks med 8-bits tall vil $120 + 10$ gå rundt, og resultatet vil være (i toerskomplement) -126 og V-flagget satt.
- **Negativ (N)**: Forteller at svaret er negativt
- **Null (Z for Zero)**: Forteller av svaret er 0

Utførende enhet kobles opp slik at A- og B-utgangene fra registerfilen kobles inn på A- og B-inngangene til ALU-en. Utgangen på ALU-en kobles inn på D-inngangen til registerfilen. Når man nå ønsker å gjøre en operasjon tar man ut to registre fra registerfilen, lar ALU gjøre en operasjon på disse, f.eks legge de sammen, og så skrive svaret tilbake til et register i registerfilen.


Ofte er det ønskelig å hente data andre steder fra enn fra registerfilen. MUX B gjør det mulig å velge noe annet enn register B som inngang til ALU, og



Figur 7.3: Utførende enhet



Figur 7.4: ALU



Figur 7.5: Styreord

MUX D gjør det mulig å skrive noe annet enn svaret fra ALU til registerfilen. Konstanten som kommer inn til MUX B vil komme fra instruksjonsregisteret, som du vil lære mer om senere. Utenfor ligger det et datalager (RAM), som kobles til linjene «Address out», «Data out» og «Data in». Dette kan man skrive til i stedet for å la data gå gjennom ALU, eller man kan lese data fra datalageret og skrive til registerfilen i stedet for det som kommer ut fra ALU.

For å sette opp den utførende enheten til å gjøre en bestemt operasjon, må alle styresignaler settes opp riktig. Her er en oversikt over styresignaler:

- DA: Registeradresse til registerfilens skriveport
- AA: Registeradresse til registerfilens leseport A
- BA: Registeradresse til registerfilens leseport B
- MB: Kontrollsignal til MUX B (velger inngang)
- FS: Velger funksjon som skal utføres av ALU
- MD: Kontrollsignal til MUX D
- WR: Angir om data skal skrives til registerfil

Styresignalene grupperes for enkelhets skyld sammen til et *styreord*, som er det styreenheten gir inn til den utførende enheten. I AOC vil formatet på styreordet være som vist i figur 7.5.

7.4 Oversikt over prosessoren

Nå vet du hva den utførende enheten er og hvordan denne kontrolleres av styresignalene i styreordet. Du har sett at ved å sette opp styreordet riktig kan du få utførende enhet til å utføre mikrooperasjoner. Neste skritt nå er å legge til de delene av prosessoren som leser inn et program og setter opp utførende enhet til å utføre dette programmet.

Som du sikkert husker om von Neumann-arkitekturen så ligger dataprogrammet lagret i et instruksjonslager (i RAM). Disse er lagret i form av en rekke instruksjoner som ligger sekvensielt i lageret. Hver instruksjon er en liten oppgave som prosessoren skal gjøre. Ofte tilsvarende dette en mikrooperasjon, men ikke alltid da noen prosessorer har kompliserte instruksjoner som utfører flere mikrooperasjoner. Prosessoren henter instruksjoner fra instruksjonslageret og finner ut hvordan disse skal oversettes til et styreord for utførende enhet, som da gjør selve jobben.

Du husker sikkert at det finnes en registerfil som inneholder generelle dataregistre brukt til utregninger. Dette er såkalte «brukersynlige» registre fordi disse brukes direkte av brukeren (dvs. programmet). I tillegg finnes det noen spesialregistre i prosessoren; registre som har helt spesielle oppgaver.

Et av de viktigste er *programtelleren* (PC for Program Counter). Programtelleren inneholder til enhver tid adressen til neste instruksjon som skal hentes fra instruksjonslageret. Hver gang en instruksjon er ferdig utført, hentes en ny instruksjon fra instruksjonslageret (med PC som adresse) og PC inkrementeres. Unntaket er for hoppinstruksjoner, da disse medfører at prosessoren skal hente instruksjoner fra en helt annen plass. PC vil da få en helt ny verdi.

Programtelleren benyttes til å slå opp i instruksjonslageret for å finne neste instruksjon. Denne instruksjonen lagres så i et *instruksjonsregister* (IR). IR inneholder altså til enhver tid den gjeldende instruksjonen.

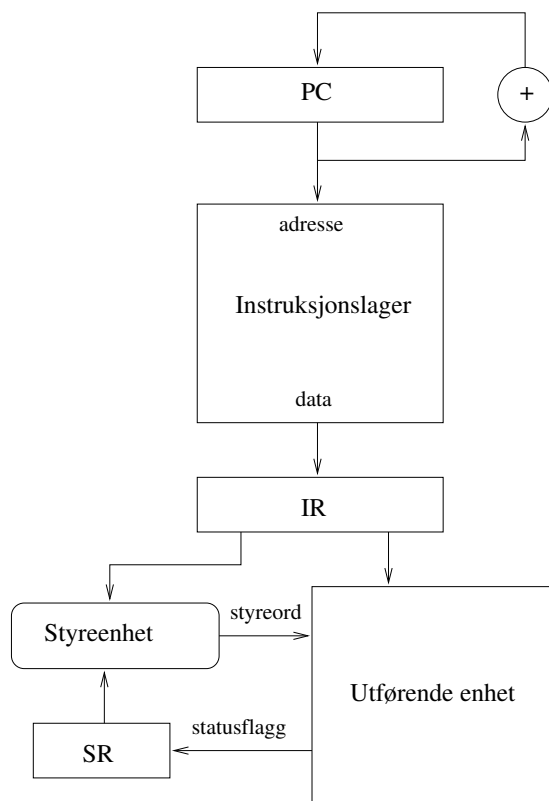
Nå kan vi legge til de delene av prosessoren som ligger utenfor utførende enhet. Dette er *forenklet* vist i figur 7.6.

Som du ser går PC rett inn på adresseinngangen til instruksjonslageret. Dette medfører at vi i neste sykel får overført instruksjonen som ligger på denne adressen til IR. Når vi har en instruksjon i IR, kan selve jobben begynne. Styreenheten undersøker instruksjonen og finner ut hva denne skal gjøre for noe. Basert på dette setter den opp styreordet til utførende enhet. Noen av kontrollsignalene (og også datasignalene) inn til utførende enhet kan komme direkte fra IR. Dette vil du lære mer om når instruksjoner og instruksjonssett forklares mer i detalj.

I tillegg til spesialregistrene nevnt ovenfor, finnes det et register som kalles *statusregister* (SR). Dette inneholder rett og slett statusflaggene fra ALU-en. I tillegg kan det inneholde noen andre flagg, f.eks et som sier om prosessoren er i system-modus (for operativsystemet) eller i bruker-modus (for alle brukerprogrammer). SR benyttes av styreenheten fordi utføring av visse instruksjoner er avhengig av innholdet i SR. Dette gjelder f.eks betingete hoppinstruksjoner, der man bare skal utføre et hopp hvis forrige instruksjon ga et gitt resultat.

7.5 Styreenheten

Styreenheten (eng: control unit) får inn data fra instruksjonsregisteret og benytter dette, sammen med statusregisteret, til å avgjøre hvordan styreordet til den



Figur 7.6: Oversikt over prosessoren

utførende enheten skal settes opp. Den sørger også for at resten av prosessoren, dvs henting av instruksjoner, skjer på riktig måte og til riktig tid.

Noen instruksjoner svarer direkte til en mikrooperasjon. Er det tilfelle kan styreenheten sette opp styreordet og gjøre seg ferdig med instruksjonen samme sykkelen instruksjonen kom til instruksjonsregisteret (IR). Andre instruksjoner kan være mer komplekse, og bestå av flere mikrooperasjoner. Er det tilfelle må styreenheten bruke flere sykler på å gjøre seg ferdig med instruksjonen, og sette opp forskjellige styreord for hver sykel.

Styreenheten er enten *fastprogrammert* eller *mikroprogrammert*.

I en fastprogrammert (hardwired) styreenhet er oppførselen bestemt av måten MUX-er, vipper og kombinatorisk logikk er koblet opp på. Dersom alle instruksjoner bare trenger én sykel (de utfører bare én mikrooperasjon i datastien), kan en fastprogrammert styreenhet bestå av ren kombinatorikk. Trengs flere sykler, kan styreenheten kobles opp ved hjelp av en tilstandsmaskin (FSM).

En mikroprogrammert styreenhet benyttes ofte dersom det finnes mange komplekse fler-sykel-instruksjoner. I stedet for å lage en stor og kompleks tilstandsmaskin kan man lage en slags «prosessor-inni-prosessoren». Styreenheten inneholder et lite lager med mikroinstruksjoner, kalt styrelageret. Dette er egentlig en rekke med ferdige styreord. Når styreenheten begynner på en ny instruksjon, så inneholder denne en adresse inn i styrelageret der den for hver sykel henter et styreord som den mater inn i den utførende enheten, helt til alle styreordene for denne instruksjonen er ferdig.

Fordelene med mikroprogrammert styreenhet er at man lett kan lage støtte for komplekse, fler-sykel-instruksjoner. Når man først har satt opp rammeverket for styreenheten vil implementering av nye instruksjoner rett og slett bestå i å endre på styrelageret. Tilsvarende vil det være enkelt å rette opp feil, da det bare vil bestå i endring av styrelageret. Etterhvert som kompleksiteten på instruksjonene økte ble dette en populær måte å implementere styreenheten på.

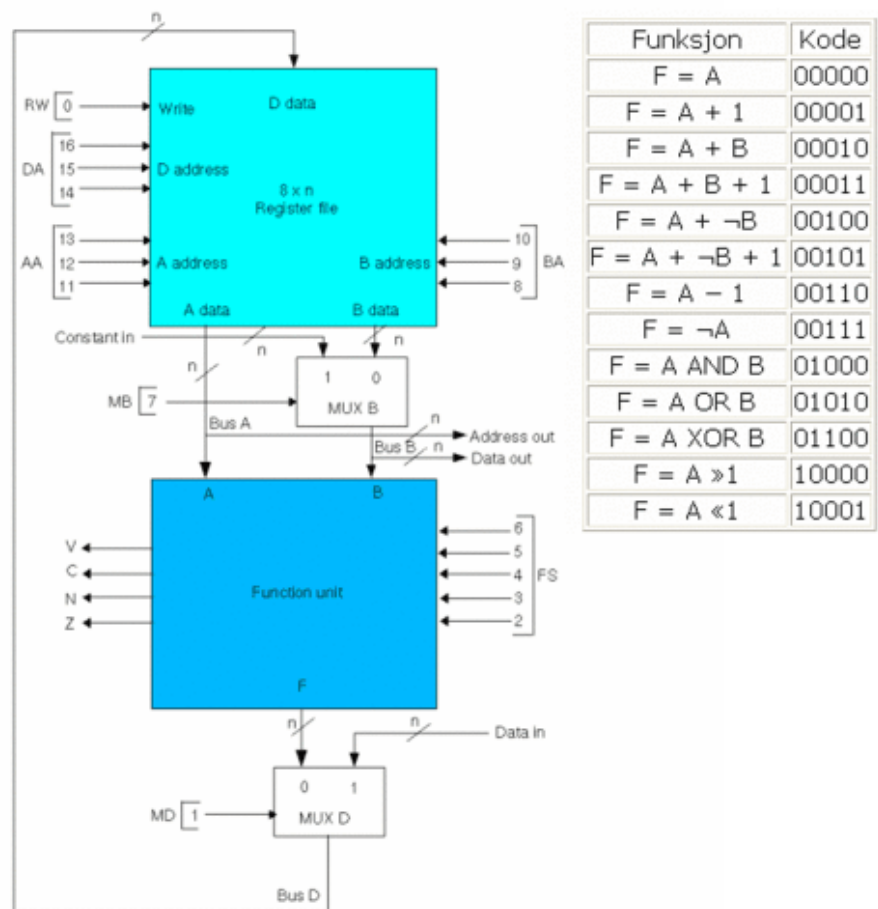
Fordelene med fastprogrammert styreenhet er at den for enkle instruksjoner kan bli både mindre, raskere og enklere å lage. I senere tid har dette blitt mer brukt igjen. Som dere vil lære senere, går man over til enklere instruksjoner – hvis man likevel deler instruksjonene inn i mindre mikroinstruksjoner, hvorfor ikke bare la instruksjonssettet bestå av slike enkle instruksjoner så slipper man dette ekstra laget. Dessuten har nye metoder innen prosessor-design minket problemene ved å lage og endre fastprogrammerte styreenheter.

7.6 Eksempel på styreord

Dette eksempelet viser hvordan man finner styreordet til en operasjon. Her skal vi vise hvordan man finner styreordet til operasjonen: $R6 \leftarrow R3 + \neg R0$.

Først vil vi finne hva DA skal være lik. Det finner vi ut ved å gjøre destinasjonsregisterne som her er R6 om til det binære tallet for seks. Første del av styreordet blir derfor som i tabell 7.2.

Deretter vil vi finne ut hva AA og BA skal være. AA er det første registeret i operasjonen, derfor skal AA inneholde den binæreverdien til R3 og BA skal inneholde den binæreverdien til R0. Om det kun hadde vært et register på høyre side av pilen hadde BA blitt representert som tre X-er. Dette er ikke tilfelle i dette eksempelet. Om man nå fyller inn for AA og BA får man styreordet i tabell 7.3.



Figur 7.7: Utførende enhet med funksjonstabell

DA	AA	BA	MB	FS	MD	RW
16-14	13-11	10-8	7	6-2	1	0

Tabell 7.1: Styreordsformat

DA	AA	BA	MB	FS	MD	RW
16-14	13-11	10-8	7	6-2	1	0
110						

Tabell 7.2: Styreord 1

DA	AA	BA	MB	FS	MD	RW
16-14	13-11	10-8	7	6-2	1	0
110	011	000				

Tabell 7.3: Styreord 2

Neste steg på veien er å finne ut hva MB skal være. Som man ser av figur 7.7 bestemmer MB om multiplekser B skal gi en konstant eller verdien som kommer fra register B. I dette eksempelet bruker register B(R0), derfor må vi sette MB slik at det som kommer ut av multiplekseren er lik innholdet til register B. Med andre ord blir MB=0 som er vist i tabell 7.4 under. Om operasjonen bestod av en konstant ville denne verdien blitt satt til MB=1. Om man ikke benytter verken register B eller en konstant settes MB=x.

Nå skal vi finne funksjonen. For å finne funksjonen må man se på tabellen som er vist i Figur 7.7. Eksempelfunksjonen vår ser slik ut: $R6 \leftarrow R3 + \neg R0$. Eksempelfunksjonen har to register på høyre side av pilen disse er i tabellen representert som A og B. Dersom man setter A og B istedenfor R3 og R0 og bytter R6 med F ser vi lett at denne operasjonen inneholder funksjonen $F = A + \neg B$. Styreordet blir da som i tabell 7.5.

MD bestemmer hva som skal komme ut av multiplekser D. Den bestemmer om det skal være data som kommer inn eller om det skal være et resultat fra den funksjonelle enheten. I dette tilfelle må MD sørge for at dataen som kommer ut fra den funksjonelle blir sendt videre. Styreordet blir da som i tabell 7.6.

Det siste bitet RW bestemmer om man skal skrive til et register eller ikke. I dette tilfelle skal man skrive til et register, derfor blir RW=1. Det endelige styreordet til operasjonen, $R6 \leftarrow R3 + \neg R0$, blir dermed som i tabell 7.7.

Husk at dersom det er likegyldig hva du setter noen av bit-ene til, skal disse settes til 'x'.

DA	AA	BA	MB	FS	MD	RW
16-14	13-11	10-8	7	6-2	1	0
110	011	000	0			

Tabell 7.4: Styreord 3

DA	AA	BA	MB	FS	MD	RW
16-14	13-11	10-8	7	6-2	1	0
110	011	000	0	00100		

Tabell 7.5: Styreord 4

DA	AA	BA	MB	FS	MD	RW
16-14	13-11	10-8	7	6-2	1	0
110	011	000	0	00100	0	

Tabell 7.6: Styreord 5

DA	AA	BA	MB	FS	MD	RW
16-14	13-11	10-8	7	6-2	1	0
110	011	000	0	00100	0	1

Tabell 7.7: Endelig styreord for $R6 \leftarrow R3 + \neg R0$

Kapittel 8

Samlebånd

8.1 Instruksjonssykel


Når prosessoren utfører en enkelt instruksjon går den gjennom flere stadier. Hvilke stadier som er nødvendige avhenger av prosessorarkitektur og instruksjon.

MIPS-prosessoren benyttes som et enkelt eksempel. Dette er en såkalt RISC-prosessor med en Load-Store-arkitektur. En LS-arkitektur medfører at alle operander må befinne seg i registerfilen. Det er altså bare mulig å gjøre operasjoner på registre, og aldri på data i datalageret. Eneste tilgang til datalageret er gjennom LOAD- og STORE-instruksjoner. LOAD leser data fra datalageret og legger i et register. STORE tar data fra et register og skriver til datalageret.

Med en slik arkitektur kan instruksjonssykel være slik:

1. *Hent* (eng: fetch): Hente instruksjon
2. *Dekod* (eng: decode): Dekode instruksjon
3. *Hent operander* (eng: operand fetch)
4. *Utfør* (eng: execute): Utføre instruksjon
5. *Lager* (eng: memory): Lese til / skrive fra datalager
6. *Tilbakeskriving* (eng: writeback): Skrive resultat av instruksjon til registerfil

Hver instruksjon må gjennom de fleste av disse stadiene hver gang de utføres. En vanlig instruksjon vil gå gjennom stadiene 1-2-3-4-6, en LOAD-instruksjon vil gå gjennom stadiene 1-2-3-5-6 og en STORE-instruksjon vil gå gjennom stadiene 1-2-3-5.



Figur 8.1: Instruksjonssykel

Hent Første stadium går ut på å hente instruksjonen fra instruksjonslageret.

Dekod Etter at instruksjonen er hentet ut må den dekodes. Dette vil si å se på instruksjonen (hovedsaklig opkoden) for å finne ut hva som skal utføres. På bakgrunn av dette settes alle styresignaler for resten av prosessoren opp. Dette gjøres av styreenheten.

Hent operander Når instruksjonen er dekodet vet styreenheten hvilke operander som trengs. Neste skritt er da å hente ut disse operandene fra registerfilen.

Utfør Når alle operander er klare har prosessoren all informasjon den trenger, og instruksjonen kan utføres. Dette gjøres av den funksjonelle enheten (skifter og ALU). F.eks for en ADD-instruksjon så er det her selve addisjonen utføres.

Lager Dersom instruksjonen er en Load/Store-instruksjon vil den gå inn i dette trinnet i stedet for «utfør»-trinnet. Her skrives eller leses datalageret.

Tilbakeskriving Til slutt må resultatet av instruksjonen lagres til riktig register i registerfilen. Dersom instruksjonen er en Store-instruksjon trengs ikke dette steget.

8.2 Samlebånd og kontrollflyt

Kontrollflytinstruksjoner er vesentlige i alle reelle programmer. Slike instruksjoner medfører hopp til et annet sted i programkoden. Men disse representerer et problem for samlebåndet. Samlebåndet fungerer bare optimalt så lenge alle samlebåndsstegene er i bruk. I begynnelsen av programmet går det noen sykler før man får fylt opp samlebåndet med instruksjoner.

En betinget hoppinstruksjon medfører at prosessoren enten fortsetter på samme sted, eller at den begynner å hente instruksjoner fra et annet sted i programlageret. Problemet er at prosessoren ikke vet om hoppet skal utføres før hoppinstruksjonen har nådd «utfør»-steget. Og selv for ubetingete hoppinstruksjoner har ofte ikke prosessoren adressen til neste instruksjon klar før hoppinstruksjonen er i «utfør».

Dersom prosessoren finner ut at hoppet ikke skal foretas så fortsetter den som om ingen ting har skjedd.

Men dersom prosessoren finner ut at hoppet *skal* tas, så må flere ting skje. Dette finner den ut først når hoppinstruksjonen er i «utfør»-steget, og instruksjonene i «hent» og «dekod» vil derfor ikke være gyldige (de er hentet fra feil plass i instruksjonslageret). Disse må «flushes», dvs. slettes. Deretter må prosessoren begynne å hente nye instruksjoner fra rett plass. Slettingen medfører tomme samlebåndssteg, og dermed dårlig utnyttelse av samlebåndet. Prosessoren har «tapt» flere sykler på å utføre hoppet.

Tabell 8.1 viser samlebåndet for en programsekvens der den tredje instruksjonen er et betinget hopp til instruksjon 8. Prosessoren vet ikke at den skal hoppe før hoppinstruksjonen er i «utfør»-steget. Instruksjon 4 og 5 vil derfor feilaktig komme inn i samlebåndet. I sykel 5 oppdager prosessoren at den skal hoppe, og sletter derfor alt som ligger i «hent»- og «dekod»-stegene (instruksjonene

	1	2	3	4	5	6	7	8	9	10	11	12
instr1	IF	ID	EX	MEM	WB							
instr2		IF	ID	EX	MEM	WB						
instr3 (hopp til 8)			IF	ID	EX	MEM	WB					
instr4				IF	ID							
instr5					IF							
instr8						IF	ID	EX	MEM	WB		
instr9							IF	ID	EX	MEM	WB	
instr10								IF	ID	EX	MEM	WB

Tabell 8.1: Samlebånd med kontrollflytinstruksjon

4 og 5). I neste sykel vil instruksjon 8 komme inn i samlebandet. Vi ser her at prosessoren har «tapt» to sykler, den har brukt to sykler på å hente inn instruksjonene 4 og 5 uten at disse skal brukes.

Det finnes flere strategier for å forbedre ytelsen i forbindelse med hopp. De fleste moderne prosessorer benytter en eller annen form for forgreningsprediksjon (eng: branch prediction). «Hent»-steget inneholder logikk, en forgreningsprediksjonsenhet (eng: branch prediction unit), som prøver å forutsi om hoppet blir tatt eller ikke, og henter instruksjoner fra stedet som den antar er rett. Dersom forutsigelsen stemmer (blir sjekket når hoppinstruksjon er i «utfør») har prosessoren spart seg for problemene i forbindelse med hopp. Dersom forutsigelsen ikke stemmer, må den slette instruksjoner akkurat som avsnittet over. Kunsten blir dermed å lage en forgreningsprediksjonsenhet som er god til å gjette utfallet av en hoppinstruksjon.

Forgreningsprediksjon kan gjøres på flere måter:

- Forutsi «aldri tatt»: Dette er det samme som en prosessor uten forgreningsprediksjon. Alle hopp som blir tatt medfører sletting.
- Forutsi «alltid tatt»: Alle hopp som IKKE blir tatt medfører sletting
- Forutsi basert på opkode: Opkoden bestemmer om hoppet forutsies tatt eller ikke. Man setter altså statisk opp hvilke instruksjoner som forutsies tatt eller ikke tatt når prosessoren konstrueres.
- Forutsi basert på hopphistorie: En hoppinstruksjon er ofte del av en løkke, og utføres gang etter gang - ofte med samme resultat (hopp eller ikke hopp). Det er sannsynlig at dersom instruksjonen medførte hopp forrige gang vil den også medføre hopp neste gang. Derfor kan en tabell benyttes til å lagre utfallet av hoppinstruksjoner. Denne kan benyttes som basis neste gang hoppinstruksjonen skal forutsies.

De tre første metodene er statiske; en hoppinstruksjon vil forutsies likt uansett hva som har skjedd tidligere. Den fjerde metoden er dynamisk; en instruksjon vil forutsies til å hoppe slik den har vist seg å hoppe tidligere i det samme programmet. Det er denne metoden som gir best resultat.

8.3 Dataavhengigheter

Det er ikke bare hoppinstruksjoner som kan lage problemer i et samleband. Gitt følgende program:

```
ADD $1, $2, $3 ; legg sammen registre 2 og 3, svaret legges i register 1
ADD $4, $1, $2 ; legg sammen registre 1 og 2, svaret legges i register 4
```

Dette er et eksempel på en *dataavhengighet* (eng: data hazard). Problemet er at den andre instruksjonen er avhengig av resultatet fra den første.

Siden operander hentes ut fra registerfilen i «dekod»-trinnet, betyr det at den andre instruksjonen må vente i «dekod»-trinnet helt til den første har forlatt «tilbakeskriving»-trinnet (man sier at instruksjonen *oppholdes* (stalles) i «dekod»-trinnet). Det blir altså et opphold på flere sykler hver gang en slik dataavhengighet oppstår. Dette er vist i tabell 8.2 der instruksjon 2 må oppholdes i 3 sykler før den kan fortsette ut av «dekod»-trinnet.

	1	2	3	4	5	6	7	8	9
instr1	IF	ID	EX	MEM	WB				
instr2 (avhengig av resultat fra instruksjon 1)		IF	ID	ID	ID	ID	EX	MEM	WB
instr3			IF	IF	IF	IF	ID	EX	MEM
instr4							IF	ID	EX
instr5								IF	ID
									EX
									MEM
									WB

Tabell 8.2: Samlebånd med dataavhengighet

Med et samlebånd er det mange situasjoner der slike avhengigheter lager problemer for instruksjonsutføringen. En egen avhengighetsenhet (eng: hazard unit) tar seg av å oppholde samlebåndssteg når dette er nødvendig på grunn av en avhengighet. Å garantere korrekt utføring av instruksjoner i et samlebånd, samtidig som man skal unngå for mye opphold av samlebåndssteg, er en av de vanskelige problemstillingene i forbindelse med konstruksjon av samlebåndsprosessorer.

8.4 RISC og CISC

Opprinnelig ble datamaskiner programmert ved hjelp av maskinkode eller assembly-språk. Instruksjonssettet til prosessoren ble laget for å være lett å programmere direkte. Etterhvert som høynivåspråk ble vanlig, ble instruksjonssettene utstyrt med instruksjoner som gjør mange av høynivåkonstruksjonene i maskinvare. Dette for å lette utviklingen av kompilatorer. Tendensen var stadig større instruksjonssett med stadig mer komplekse instruksjoner.

Etterhvert begynte en gruppe mennesker å se på mønstre i høynivå-generert maskinkode. Resultatene av disse studiene resulterte i en filosofi om å gjøre maskinvare som støtter høynivåspråk *enkler*, ikke mer kompleks.

Noen observasjoner som ble gjort:

- Folk programmerer ikke assembly lengere; ingen vits å lage et instruksjonssett som passer for hånd-koding.
- Komplekse instruksjoner blir sjeldent brukt av kompilatorer fordi det er vanskelig for kompilatoren å generere kode som passer til en kompleks, spesialisert instruksjon. Som oftest er det små enkle instruksjoner som dominerer. Det er derfor ingen vits å bruke dyr silisium på å implementere komplekse instruksjoner.
- Enkle instruksjoner er det enkelt å lage maskinvare for. Spesiellages instruksjonssettet slik at det er lett å få til samlebånd, så vil det bli lettere å lage en rask prosessor.
- En liten andel av de ulike instruksjonstypene utgjorde en meget stor andel av de instruksjoner som blir utført av prosessoren.

Dette medførte en ny prosessor-design-filosofi: RISC (Reduced Instruction Set Computer). Til sammenligning ble de tidligere prosessorarkitekturer kalt CISC-arkitekturer (Complex Instruction Set Computer). Merk at det ikke finnes noen klar definisjon på det ene eller det andre.

Vanlige egenskaper ved RISC:

- Få og enkle instruksjoner – enkle instruksjoner medfører enkel maskinvare
- Én instruksjon pr. sykel (pluss evt. samlebåndsoppholding)
- Load/Store-arkitektur; man kan ikke gjøre aritmetikk på operander i RAM. RAM får man tilgang til kun gjennom egne LOAD og STORE-instruksjoner.
- Enkle adresseringsmodi

- Enkle og få instruksjonsformater. Instruksjonsordet har ofte samme lengde for alle instruksjoner.
- Stor registerfil. En Load/Store-arkitektur medfører at man stort sett bare jobber på registre. Mange generelle registre gjør at man slipper å bruke sykler på å lese/skrive til RAM.

Vanlige egenskaper ved CISC:

- Mange og komplekse instruksjoner. Medfører komplisert kontrollenhet, og er ofte vanskelig å lage et godt samlebånd til
- Kan bruke mange sykler for å utføre én instruksjon, f.eks en kompleks løkke-instruksjon
- Ofte mange adresseringsmodi, med mulighet for operander i RAM
- Kompliserte og lange instruksjonsformater
- Få generelle registre

En RISC-prosessor vil være enklere å konstruere enn en CISC-prosessor. Den enkle arkitekturen er lettere å implementere og samlebåndet blir enklere. Enklere arkitektur betyr mindre og raskere krets. Siden mindre plass blir brukt til logikk, får man plass til desto større registerfil og cache.

RISC-prosessorer har vist seg å ha mange gode egenskaper. Det er likevel få rene RISC-prosessorer i dag. Det finnes også få rene CISC-prosessorer. Nye prosessorer har en tendens til å ligne mest på RISC-prosessorer, men med noen CISC-lignende konstruksjoner i tillegg.

8.5 Instruksjonssykel i maskinvare

Det finnes mange måter å realisere instruksjonssykel i maskinvare på, hver med sine fordeler og ulemper.

Prosessoren jobber i takt med et klokkesignal. Frekvensen av denne klokken benyttes ofte (feilaktig) som et mål på hvor rask en prosessor er. Dette blir feil fordi det er stor variasjon mellom prosessorarmodeller når det gjelder hvor mye de gjør pr. klokkesykel.

8.5.1 En-sykelmaskin

Prosessoren kan lages som en en-sykelmaskin, det vil si at alle stadiene i instruksjonssykel utføres i samme klokkesykel. Da får man utført én instruksjon pr. sykel, dvs. en CPI (Cycle Per Instruction) på 1,0. Dette medfører som oftest svært lav klokkefrekvens fordi kritisk sti (lengste sti gjennom prosessoren m.h.p tidsforbruk) blir svært lang – «Alt» må gjøres på en eneste sykel. Man må ha en klokke som går sakte.

8.5.2 Fler-sykelmaskin

En annen arkitektur kan være en fler-sykelmaskin. Her vil man benytte flere klokkesykler for å utføre en instruksjon. Man kan for eksempel bruke én sykel på hvert av stegene i instruksjonssykel slik at man får én sykel på å hente instruksjonen, én sykel på å dekode etc. Fordelen med dette er kort kritisk sti og dermed høy klokkefrekvens. Ulempen er at man bruker mange sykler pr. instruksjon ($CPI > 1,0$), og prosessoren får gjort mindre pr. klokkesykel.

8.5.3 Samlebåndsmaskin

Det finnes en måte å få til høy klokkefrekvens på, samtidig som man i gjennomsnitt får utført (nesten) én instruksjon pr. klokkesykel. Denne teknikken kalles *samlebånd* og benyttes i alle prosessorer der høy ytelse er vesentlig.

Samlebånd kan illustreres med et hverdagslig eksempel: Tenk deg at du skal vaske klær og har én vaskemaskin og én tørketrommel til rådighet. Vaskemaskinen er bare stor nok til å ta halvparten av klærne, så du må derfor kjøre to runder i vaskemaskinen. Den naive måten å ta vasken på vil være slik:

- Vaske første halvpart av klærne
- Tørketromle første halvpart av klærne
- Vaske andre halvpart av klærne
- Tørketromle andre halvpart av klærne


Dette er lite effektivt. Til enhver tid står enten vaskemaskinen eller tørketrommelen ubrukt. Da er det bedre å gjøre det på samlebåndsmetoden:

- Vaske første halvpart av klærne
- Tørketromle første halvpart av klærne, samtidig som du vasker andre halvpart
- Tørketromle andre halvpart av klærne

Nå har du spart én operasjon. Og dersom du har mange runder med klesvask, vil du spare mye mer.

Samme gjelder for prosessorer. Den viktige observasjonen her er altså at de forskjellige stegene i instruksjonssykel benytter forskjellige enheter:

- Steg 1 (Hent) benytter instruksjonslageret
- Steg 2 (Dekod) benytter dekodingslogikken
- Steg 3 (Hent operander) leser fra registerfil
- Steg 4 (Utfør) benytter den funksjonelle enheten
- Steg 5 (Lager) benytter datalageret
- Steg 6 (Tilbakeskriving) skriver til registerfil. Skrivning til registerfil skjer uavhengig av lesing, og dette steget vil derfor ikke være avhengig av hva som skjer i steg 3.



Figur 8.2: MIPS samlebånd

Dette kan man utnytte. I stedet for å ta hver instruksjon for seg og dermed la de fleste enheter være ubrukt mesteparten av tiden, kan man la alle enheter jobbe hele tiden. Man splitter prosessoren inn i samlebåndssteg som tilsvarer stegene i instruksjonssyklusen. En instruksjon vil først komme inn i samlebåndssteg 1. Neste syklus går den videre til samlebåndssteg 2 etc., helt til den er ferdig med alle samlebåndsstegene. Siden stegene er uavhengige av hverandre kan man etter at første instruksjon har nådd steg 2, ta inn en ny instruksjon i steg 1. På denne måten vil man kunne fylle opp samlebåndet slik at hvert samlebåndssteg inneholder en instruksjon. Prosessoren jobber altså med mange forskjellige instruksjoner på én gang, på hvert sitt sted i instruksjonssyklusen.

Som eksempel brukes samlebåndet til MIPS-prosessoren. Denne har 5 samlebåndssteg. Disse tilsvarer stegene i instruksjonssyklusen, bortsett fra at «Decode» og «Operand Fetch» er slått sammen til ett samlebåndssteg.

Instruksjoner flyter fra venstre til høyre i figur 8.2: Først når de «Hent», deretter «Dekod», «Utfør», «Lager» og «Tilbakeskriving». Alle instruksjoner går gjennom alle samlebåndssteg. Selv om en instruksjon ikke benytter seg av ressursene i ett av stegene så vil den likevel gå gjennom dette steget. Samlebåndets natur gjør at det ikke er noe poeng i at en instruksjon hopper over et steg – neste instruksjon vil uansett ikke bli ferdig tidligere.

Eksempel

Tenk deg et program på 8 instruksjoner. Disse vil flyte gjennom samlebåndet på denne måten:

Figuren viser klokkesyklus (tid) horisontalt, og instruksjoner vertikalt. IF = Hent, ID = Dekod, EX = Utfør, MEM = Lager, WB = Tilbakeskriving.

På syklus 1 vil første instruksjon komme inn i «hent»-steget. På syklus 2 vil første instruksjon fortsette til «dekod»-steget, samtidig som at andre instruksjon kommer inn i «hent»-steget. Slik fortsetter det. På syklus 6 er første instruksjon ferdig. Og nå ser man fordelingen med samlebånd: Heretter blir det ferdigstilt en instruksjon for hver eneste syklus. Og alle samlebåndsstegene er i bruk samtidig.

Disse 8 instruksjonene bruker 12 sykler på å gjøre seg ferdig. Dette kan regnes ut slik (der # betyr «antall»):

$$\#sykler = \#samlebåndssteg + \#instruksjoner - 1$$

Siden antall samlebåndssteg er konstant, ser vi at et samlebånd kan gi en CPI (cycles per instruction) tilnærmet lik 1,0 når antall instruksjoner er stort. Altså nesten like bra som en én-syklus-maskin, men med den høye klokkefrekvensen til en fler-syklus-maskin.

	1	2	3	4	5	6	7	8	9	10	11	12
instr1	IF											
instr2		ID										
instr3			ID									
instr4				ID								
instr5					ID							
instr6						ID						
instr7							ID					
instr8								ID				

Tabell 8.3: Instruksjonsflyt gjennom samlebandet

Kapittel 9

Eksempler på prosessorer

9.1 Intel x86

Intels x86-familie av prosessorer er blant de mest solgte prosessorer for vanlige PC-er. Intels mikroprosessorhistorie kan oppsummeres slik:

9.1.1 4-bits prosessorer


1970: Intel 4004

- Verdens første kommersielt tilgjengelige mikroprosessor (prosessor på én mikrobrikke).
- 2250 transistorer.


9.1.2 8-bits prosessorer

1972: Intel 8008


- 8-bits versjon av 4004.
- 3300 transistorer.



Figur 9.1: Intel 4004



Figur 9.2: Intel 8008



Figur 9.3: Intel 8086

1974: Intel 8080

- Mye brukt 8-bits prosessor, bl.a brukt i Altair. Altair er en av de første datamaskiner laget for hjemmebruk.
- 4500 transistorer.

9.1.3 16-bits prosessorer

1978: Intel 8086

- 29 000 transistorer

1983: Intel 80286

- 134 000 transistorer


9.1.4 32-bits prosessorer

1985: Intel 80386


- 275 000 transistorer

1989: Intel 80486

- 1,2 millioner transistorer



Figur 9.4: Intel 80386



Figur 9.5: Intel Pentium 4

1993: Intel Pentium

- Superskalar
- 3,2 millioner transistorer

1995: Intel Pentium Pro

- 5,5 millioner transistorer

1997: Intel Pentium II

- 7,5 millioner transistorer

1999: Intel Pentium III

- 9,5 millioner transistorer

2000: Intel Pentium 4

- 42 millioner transistorer

Alle disse prosessorene er i slekt med hverandre. Intel har hele tiden valgt å holde sine prosessorer bakoverkompatible. Dette gjør at i en Pentium 4 finnes det mye historisk ballast, og arkitektur og instruksjonssett er mye «styggere» enn det ville vært dersom prosessoren var designet uten tanke på bakoverkompatibilitet. Familien (kalt x86) har likevel holdt seg i live bemerkelsesverdig bra og Intel har gjort en stor jobb med å holde en ellers utdatert arkitektur rask og moderne.

Frem til og med 80486-prosessoren var alle Intels prosessorer tradisjonelle CISC-maskiner. For å beholde bakoverkompatibilitet er fremdeles instruksjonssettet CISC-aktig i moderne Pentium-er, men arkitekturen er mer RISC-lignende. I en Pentium 4 vil hver instruksjon oversettes til flere mindre RISC-lignende instruksjoner som utføres i en RISC-lignende prosessor. Prosessoren består altså av et CISC-skall bygget rundt en RISC-kjerne. Pentium 4 har et samleband med minst 20 trinn.

På grunn av sin CISC-fortid har Pentium en rekke forskjellige instruksjonsformater, og instruksjonene har også forskjellige lengder. Det finnes 8 generelle 32-bits registre.

9.2 PowerPC

PowerPC (PPC) bygger på arkitekturen til IBMs RISC System/6000, også kalt POWER-arkitekturen. Den er et samarbeidsprosjekt mellom IBM, Motorola (kjent for 680x0-prosessorene) og Apple. Disse benyttes (enn så lenge) i Apple Macintosh-datamaskiner og har (i Apples tilfelle) avløst Motorolas 680x0-prosessorer.

PowerPC er en RISC-prosessor. Alle instruksjoner er på 32 bits, og følger et regulært format. Det finnes 32 generelle 64-bits registre.

Kapittel 10

I/O

10.1 Introduksjon til I/O

En prosessor som jobber for seg selv uten kontakt med omverdenen er det ikke mye nytte i. Derfor kobler man til I/O-enheter (I/O er forkortelse for Input/Output), som er et grensesnitt mot den virkelige verden.

Eksempler på I/O-enheter:

- Tastatur
- Skriver
- Skjerm
- Harddisk

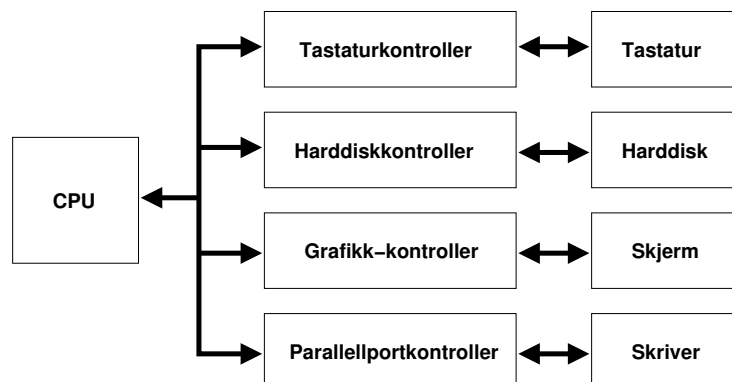
Slike I/O-enheter kan styres direkte av prosessoren. Det gjøres nesten aldri fordi det kan være både komplisert og prosessorintensivt å styre slike enheter. Derfor benyttes i stedet en *I/O-kontroller* (også kalt I/O-modul) som tar seg av styring av I/O-enheten. Denne sitter mellom prosessoren og I/O-enheten, og gir prosessoren et enkelt grensesnitt mot I/O-enheten.

En I/O-kontroller har flere oppgaver:

- Kommunikasjon med I/O-enhet
- Kommunikasjon med CPU
- Mellomlagre data slik at CPU kan lese og skrive data når det passer, og ikke når I/O-enheten krever det
- Feildeteksjon og rapportering av I/O-enhetens tilstand

10.2 Kommunikasjon mellom CPU og I/O-kontrollere

Prosessoren kommuniserer ikke direkte med en I/O-enhet. I stedet kommuniserer den med en I/O-kontroller. Det finnes flere måter prosessoren kan kommunisere med I/O-kontrolleren på:



Figur 10.1: I/O-kontrollere og enheter

10.2.1 Programmert I/O (polling)

Dette er den enkleste og mest ressurskrevende formen for I/O-operasjoner. Hvis man bruker programmert I/O vil dette foregå på følgende måte: Når en prosessor ønsker å skrive eller lese data fra en I/O-enhet, vil den sende en kommando til I/O-kontrolleren. I/O-kontrolleren vil så kontakte I/O-enheten på vegne av prosessoren og utføre oppgaven. Dersom data leses fra I/O-enheten vil I/O-kontrolleren legge de i en intern buffer. Prosessoren må hele tiden sjekke status på I/O-kontrolleren for å vite om den har data klare fra I/O-enheten i bufferet sitt. Dette fører til at mye prosessorkraft går med til å sjekke status.

10.2.2 Avbruddsdrevet I/O

Problemet med programmert I/O er at prosessoren er nødt til hele tiden å sjekke status til I/O-kontrolleren. Et alternativ er avbruddsdrevet I/O. Ved avbruddsdrevet I/O sender prosessoren en forespørsel til I/O-kontrolleren og fortsetter med andre beregninger. Når I/O-kontrolleren er klar til å utveksle data med prosessoren vil den sende et avbruddssignal. Prosessoren vet da at data er i bufferet og overfører disse fra bufferet til primærlageret, før I/O-kontrolleren behandler resten av I/O forespørselen. Dette fører til at vi får en minimal kostnad for prosessoren å sjekke om data er klare.

En analogi til dette er hvis man ser på prosessoren som eieren av et hus, dataene som skal overføres som gjester som skal inn i huset. Hvis man da skal illustrere programmert I/O vil det være som om huset ikke hadde ringeklokke, og eieren måtte med jevne mellomrom gå ut på trappen for å sjekke om det er kommet gjester. Derimot hvis man bruker avbruddsdrevet I/O vil man ha ringeklokke på huset, slik at eieren slipper å gå ut å sjekke om det står noen på trappen hele tiden, han må bare passe på å lytte om ringeklokken ringer.

10.3 DMA

Avbruddsdrevet I/O er som regel mer effektivt enn programmert I/O, men det har sine ulemper: Prosessoren må selv overføre data fra I/O-kontrolleren til

lageret. Selv om prosessoren kan gjøre andre ting mens I/O-kontrolleren jobber, må den fremdeles ta seg av selve dataoverføringen.

Løsningen på dette er å sette en annen og mindre prosessor til å ta seg av I/O-overføringer. Denne teknikken kalles DMA (Direct Memory Access) - DMA-kontrolleren har direkte tilgang til lageret og data trenger ikke gå via prosessoren.

Ved bruk av DMA blir data overført på følgende måte: CPU-en sender en forespørsel til DMA-kontrolleren om å gjøre en overføring av data fra en I/O enhet til primærlageret. CPU-en blir så frigitt til å gjøre andre beregninger mens den venter på signal fra DMA-kontrolleren. Når I/O overføringen er ferdig, sender DMA-kontrolleren et avbrudd til prosessoren som forteller at data som er forespurt ligger klar i lageret.

Når DMA-kontrolleren skal overføre data er den nødt til bruke systembussen. DMA-kontrolleren må vente på at denne er ledig, eller den må tvinge prosessoren til å gi den fra seg i en kort periode. Den siste muligheten er det som oftest blir brukt og kalles «sykelstjeling» (eng: cycle stealing)

Husker du analogien om huset? Et hus med DMA-egenskaper ville hatt en hovmester. Når gjestene kommer vil hovmesteren sørge for å ta de med til stuen din. Du trenger ikke åpne for dem selv. Hovmesteren vil gi deg beskjed om at gjestene er på plass. En hovmester vil være mest hensiktsmessig hvis du får veldig mange gjester, akkurat som for DMA som er mest hensiktsmessig hvis du skal overføre store datamengder.

10.4 Busser

En buss er en kommunikasjonsvei som kobler sammen to eller flere enheter. Den er altså et kommunikasjonsmedium. Kun én enhet kan sende noe over en buss på et gitt tidspunkt, men alle de andre enhetene som er koblet til bussen kan motta. En buss består typisk av flere kommunikasjonslinjer, hver med mulighet til å sende et binært signal. En vanlig PC har koblet til seg ulike busser f.eks. systembussen, IDE, Firewire, USB, SCSI, PCI, AGP og ISA.

Systembussen i en datamaskin består typisk av femti til hundrevis av separate linjer, hver har sin egen funksjon. Det finnes mange forskjellige bussarkitekturer, men i hovedtrekk kan vi gruppere linjene i data-, adresse- og styre-linjer.

På *datalinjene* overføres data som skal sendes. Bredden (antallet linjer) på databussen bestemmer hvor mye data som kan overføres for hver klokkesykel. Det er ikke nødvendigvis slik at jo flere datalinjer jo raskere er bussen. Hvis man sender data over en linje (serielt) kan man ofte overføre med høyere hastighet fordi man bl.a slipper problemene med å få data på alle datalinjene synkronisert.

Adresselinjene forteller hvor kilden eller destinasjonen til dataene er. Hvis f.eks. prosessoren skal lese fra en gitt minneadresse legges denne adressen på adresselinjene slik at minnet vet hvilket ord som skal legges på datalinjene. Antall adresselinjer avgjør selvsagt hvor stort adresseområde som kan nås via denne bussen.

Styrelinjene brukes til å styre hva bussen skal brukes til, f.eks hvem som skal skrive til den.

10.4.1 Bussarkitektur

Når man kobler mange enheter til en buss vil man generelt få en tregere buss. Dette skyldes i hovedsak to ting:

- Bussen blir fysisk lengre og tiden det tar for det elektriske signalet å komme fra den ene siden av bussen til den andre øker. Dermed er man nødt til å senke frekvensen på bussen slik at man er sikker på at alle enhetene mottok siste signal på bussen, før man begynner å sende et nytt. Hvis to signaler blir sendt samtidig vil signalene bli ødelagt.
- Når man kobler flere enheter til bussen vil konkurransen om å få sende over bussen øke. Dermed vil sannsynligvis enhetene bruke mer tid på å vente på å få kontroll over bussen.

Løsningen på dette problemet er å dele opp bussen i flere nivåer, det vil si at vi i prinsippet sitter igjen med flere busser som er koblet sammen med broer (enheter som kobler sammen forskjellige busser). I PC-er har man et hierarki av busser med ulik hastighet. Dette er vist i figur 10.2. Prosessoren er koblet til systembussen, der primærlageret befinner seg. Systembussen kobles sammen med en høyhastighets ekspansjonsbuss gjennom en bro. Her kobles enheter som trenger rask overføring av data. Nederst er en lavhastighets ekspansjonsbuss for trege enheter.

10.4.2 Multiplekset buss

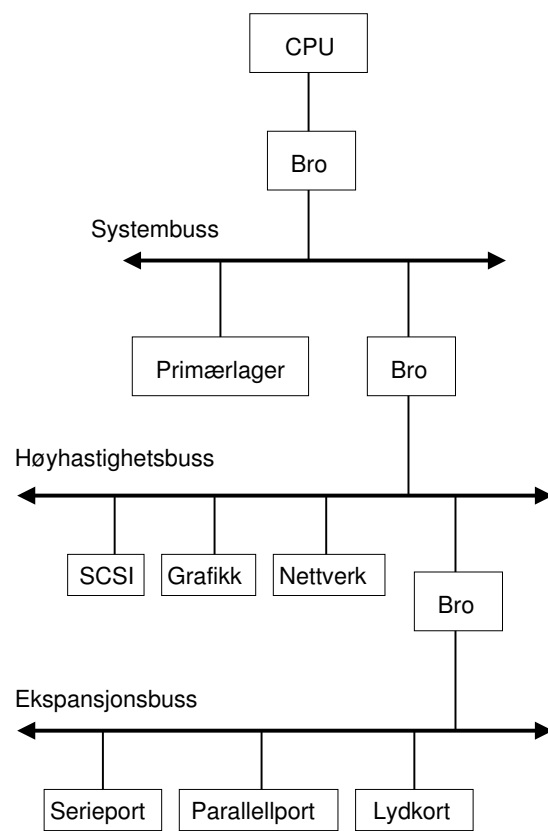
De forskjellige roller til linjene i bussen (adresse, data og styring) ble beskrevet over. Man kan ha en buss der noen av de fysiske linjene har flere roller. Man kan f.eks ha 32 datalinjer som også kan fungere som 32 adresselinjer. Dette kalles *multiplekset buss*. En bussoverføring som tar flere sykler å gjennomføre vil kunne sette av 32 linjer i 1. sykel til adresse, for så å bruke de samme linjene i neste sykel til data. På denne måten vil man få færre antall linjer i bussen, og dermed en enklere buss å håndtere fysisk. Linjer som ikke er multiplekset kalles *dedikerte*.

10.4.3 Arbitrering


En buss kan ha en spesiell enhet som alltid bestemmer hvem som skal skrive til bussen. Vi har en *herre* (eng: master) og flere *slaver* (eng: slave).

Noen busser kan ha flere herrer. Da får vi et problem med å styre hvem som skal ha kontrollen over bussen til enhver tid.


Dette løses vha *arbitrering*, som er navnet på teknikker der enhetene forhandler om hvem som skal få styre bussen. De forskjellige arbitreringsteknikkene kan grovt sett deles inn i to grupper: sentral og distribuert. Ved sentral arbitrering er det en enhet, gjerne en busskontroller, som har kontroll over bussen og den bestemmer hvilke enheter som har lov til å bruke bussen. Ved distribuert arbitrering finnes det ingen sentral kontroller, enheten må bli enige seg i mellom hvem som skal bruke bussen. Dersom arbitreringen skjer uten å «bruke opp» sykler for dataoverføringen, kalles arbitreringen for «skjult».



Figur 10.2: Busshierarki



Figur 10.3: Synkron tidsstyring



Figur 10.4: Asynkron tidsstyring

10.4.4 Timing (tidsstyring)

Timing refererer til hvordan hendelser er koordinert over bussen. Busser er enten synkrone eller asynkrone.

Ved synkron timing er det en klokke som avgjør når og hvor lenge et signal skal ligge på bussen. Denne klokken må være felles for alle enhetene som ligger på bussen, og klokkesignalet er typisk en del av styrelinjene. Sykeltiden må tilpasses slik at den er lang nok selv for den tregeste enheten.

Dette er vist i figur 10.3. Vi har et klokkesignal, en adressebuss, en databuss og et signal som forteller at bussens herre ønsker å skrive til bussen. Når skriveoperasjonen skal starte, settes adresse- og databuss opp med riktige verdier, og skrivesignalet settes høy. Dette indikerer at alle enheter som skal lese bussen må lese adresse- og databuss på starten av neste klokkesykel.

Ved asynkron timing brukes styrelinjer til å fortelle at det ligger et gyldig signal på bussen, slik at den enheten som skal lese dette vet at signalet er klart til lesing. Tilsvarende vil det finnes styrelinjer som forteller at signalet er lest, og dermed kan fjernes igjen.

Dette er vist i figur 10.4. Her er det ikke noe klokkesignal som forteller når data skal skrives og leses. I stedet finnes et kvitteringssignal. Herren setter opp adressebuss og databuss som før, og setter deretter skrivesignalet. Nå vet slaven at den kan lese data fra bussen. Etter at slaven har lest data, setter slaven opp kvitteringssignalet for å fortelle at herren kan fjerne data fra bussen og fortsette med andre ting.

Forskjellen her er altså at vi i en synkron buss har et klokkesignal som dikterer hvor lenge data skal være tilgjengelige og når data skal skrives/leses. I en asynkron buss vil data ligge tilgjengelige helt til slaven har indikert at den er ferdig (gjøres med kvitteringssignalet).

10.5 Eksterne busser

Eksterne busser brukes til å koble til I/O-enheter av forskjellig slag. Dette kan være mus, tastatur, lagringsmedier etc.

Vi deler eksterne busser inn i to hovedkategorier: parallelle og serielle. I parallelle busser er det flere linjer som kobler sammen enhetene, og flere bit blir overført samtidig. I serielle busser brukes kun en linje for å transportere data slik at kun en og en bit kan overføres til samme tid. Eksempel på parallelle busser er SCSI, mens FireWire, USB, FibreChannel og Serial ATA alle er serielle.

SCSI (Small Computer System Interface) var først vanlig på Macintosh på 80-tallet, men brukes nå også i PC-er og arbeidsstasjoner. Brukes som regel som grensesnitt mot CD-ROM, harddisker, scannere osv. SCSI støtter 8-16 enheter pr. SCSI-kontroller og hastigheter opptil 320 MB/s.

FireWire (IEEE 1394) bruker som sagt seriell overføring noe som fører til billigere kabler og kontakter, mindre kontakter, enkel implementasjon samt at man unngår synkroniseringsproblemer. FireWire støtter hastigheter opptil 400 Mbps og 63 enheter. Dessuten støttes både «Hot plugging» (mulighet for å koble til enheter mens strømmen er på) og «Plug and Play» (system som gjør at brukeren ikke trenger gjøre noe aktivt for å få enheten til å virke).

USB (Universal Serial Bus) brukes til enheter med lav eller medium datarate (12Mb/s = 1,5MB/s). Opptil 127 enheter kan tilkobles samtidig og USB støtter både «Hot Plugging» og «Plug and Play». Brukes gjerne til enheter som ikke bruker mye båndbredde slik som: mus, tastatur, modem, printer osv. Etterhvert har denne standarden blitt oppdatert til versjon 2.0 som øker båndbredden til 480Mbps og er bakoverkompatibel med tidligere versjoner.

FibreChannel er tenkt som en erstatning til SCSI. FibreChannel støtter deling av lagringsenheter mellom tjenere (SAN = Storage Area Network), 100-200MB/s i hver retning (seriell), og kan bruke kabellengder på opp til 10km (med optisk fiber).

Serial ATA er tenkt som den serielle erstatningen til ATA (for harddisker, CD-ROM osv). Kabelen bruker kun 7 ledere og overføringsrater er 150MB/s. Kommende versjoner vil ha overføringsrater på 300 og 600 MB/s.

Kapittel 11

Primærlager

11.1 Oversikt over lageret

Lageret i datamaskinen er den delen av maskinen der data (og program) ligger lagret. Det finnes flere typer lager i en datamaskin. De viktigste karakteristikkene til de forskjellige typene er kostnad, kapasitet og aksesstid. Det optimale lager har minimal kostnad, minimal aksesstid og maksimal kapasitet, men det er umulig å oppnå.

11.1.1 Lagerhierarki

Det ble observert at selv om et program trenger et stort lager vil prosessoren stort sett bare jobbe på et lite subsett av gangen. Dette subsettet vil gradvis skiftes ut over tid men innen et lite tidsintervall er det et relativt lite sett av data som er «aktivt».


Dette er essensen i *lokalitetsprinsippet*. Vi har lokalitet i lagerreferanser. Det finnes to typer lokalitet:

- Temporær lokalitet; hvis prosessoren har gjort en aksess til en spesiell lagercelle er det sannsynlig at det blir gjort en aksess til samme lagercelle i nær fremtid
- Romlig lokalitet; hvis prosessoren har gjort en aksess til en spesiell lagercelle er det sannsynlig at det blir gjort en aksess til en nærliggende lagercelle i nær fremtid

Denne egenskapen kan utnyttes. Vi kan lage et stort lager som ikke er særlig raskt. I tillegg lager vi et lite og raskt lager som «bufrer» (dvs. inneholder en kopi av) det aktive datasettet som prosessoren jobber på for øyeblikket. Dersom vi klarer å ordne det slik at prosessoren nesten alltid finner data i det lille lageret vil vi få en enorm hastighetsøkning, samtidig som at prosessoren har mulighet til å benytte hele det store lageret. Dette kalles hurtigbufring og er en sentral del av arkitekturen i en moderne PC.

En moderne PC har ikke bare to nivåer med lager slik som forklart over. Lageret er ordnet i et hierarki med flere forskjellige lagernivåer som hver bufre data fra nivået under.

Lagerhierarkiet ser vanligvis slik ut:



Figur 11.1: Lagerhierarki

- Registres
- Hurtigbuffer, nivå 1
- Hurtigbuffer, nivå 2
- Primærlager
- *Harddisk*
- *Sikkerhetskopier på kassett*

Hierarkiet viser hvor nær de forskjellige lagertypene er prosessoren. Øverst finnes registrene, som prosessoren kan benytte direkte i utregninger. Registres er raske, men få i antall. Nederste nivå i lagerhierarkiet inneholder alle data. Hvert nivå oppover i hierarkiet inneholder en kopi av data fra nivået under.

Etter hvert som man går ned i hierarkiet:

- Minker kostnaden per bit
- Øker kapasiteten
- Øker aksesstiden
- Kommer lenger og lenger bort fra prosessoren

For å illustrere forskjellen i størrelse, tegnes ofte hierarkiet som en trekant, som vist i figur 11.1.

Primærlageret er det lageret prosessoren «ser». Alle hurtigbufrene er transparente for prosessoren da bufning av korrekt data skjer automatisk.

Under primærlageret finnes det to nivåer til: harddisk og magnetbånd. Dette sees ikke direkte av prosessoren. Støtte i operativsystemet kan benyttes til å inkludere disse i hierarkiet (kalles virtuelt lager).

11.1.2 Lagertypenes kapasitet

Alle lager har en viss kapasitet, som måles i antall byte eller ord. I en vanlig PC (i 2004) vil størrelsen på...

- ...hurtigbuffer nivå 1 være ca 8kB-32kB
- ...hurtigbuffer nivå 2 ca 256kB-2MB
- ...primærlageret være mellom 128MB-1GB
- ...sekundærlageret (harddisk) være mellom 30-160GB

11.1.3 Lagertypenes aksessmetoder

En annen forskjell mellom lagertypene er aksessmetoder.

- Sekvensiell aksess: Starter på begynnelsen og leser gjennom lagerenheten i en lineær sekvens. Aksesstid avhenger av hvor data befinner seg. Brukes for eksempel i magnetbånd.
- Blokk-direkte aksess: Hver blokk (som er en samling med data) har en unik adresse. Man aksesserer data ved å hoppe direkte til riktig blokk og leter sekvensielt gjennom den etter ønsket data. Aksesstid avhenger av hvor data befinner seg. Brukes for eksempel i harddisker
- Direkte aksess: Hver datacelle kan adresseres direkte, dvs. man kan hoppe direkte til de data man ønsker. Brukes for eksempel i RAM
- Assosiativ aksess: Man identifiserer lagringssted basert på deler av innholdet i stedet for adresse. Brukes for eksempel i hurtigbuffer.

11.1.4 Lagertypenes ytelse


De ulike lagertypene har ulik ytelse. Ytelsen blir målt med tre størrelser:

- Aksesstid: For direkte aksess er dette tiden en leseoperasjon eller en skriveoperasjon tar, for andre typer aksess er det tiden det tar å sette les/skrive mekanismen på rett plass.
- Sykeltid: Et konsept som er mest brukt ved RAM. Sykeltiden er aksesstid pluss tiden man trenger før neste aksess kan begynne
- Overføringsrate: Vil si hvor mye data man kan overføre per tidsenhet. For direkte aksess er overføringsraten lik $1/\text{sykeltiden}$. For andre typer har man formelen

$$T(N) = T_a + (N/R)$$

der

- $T(N)$ er gjennomsnittlig tid for lesing eller skriving av N bit
- T_a er gjennomsnittlig aksesstid, N er antall bit
- R er overføringsraten i bit per sekund(bps).



Figur 11.2: EPROM

11.2 ROM

ROM (Read Only Memory) kan leses på samme måte som RAM. Men man kan ikke skrive nye data inn til den. Man trenger ikke strøm for å holde på verdiene i ROM.

Det finnes flere typer; ROM, PROM, EPROM, EEPROM og Flash.

11.2.1 ROM

ROM har data fastprogrammert inn i brikken som en del av fabrikkeringsprosessen.

Et problem med ROM er at den må fabrikkeres med riktig innhold, noe som gjør det dyrt å lage noen få ROM-brikker. Det lønner seg ikke før man skal lage tusenvis.

Man bruker ROM til oppstartsrutiner og biblioteksfunksjoner i enheter som lages i stort antall.

11.2.2 Programmerbar ROM (PROM)

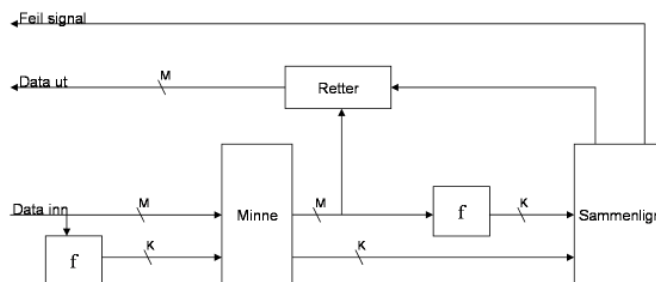
Innhold kan skrives elektronisk første gang, dvs. at innholdet ikke er fastprogrammert ved produksjon. Dette gjør den mer velegnet enn vanlig ROM når man trenger et lite antall brikker.

11.2.3 Slettbar PROM (Erasable PROM - EPROM)

EPROM kan slettes ved å bruke UV-lys, slik at man kan skrive nye data til den mer enn en gang. Ulempen er at det tar lang tid, og krever UV-belysning av brikken. Belysning skjer gjennom et vindu på brikken, vist i figur 11.2.

11.2.4 Elektronisk slettbar PROM (Electronically Erasable PROM - EEPROM)

I en EEPROM kan innholdet slettes elektronisk. På samme måte som for EPROM kan man dermed skrive nytt innhold flere ganger, men man slipper å belyse



Figur 11.3: Generell feilkorrigering

brikken mellom hver gang. Sletting skjer byte-vis. Sletting/skriving er tregt og EEPROM-er er dyre. På grunn av treg hastighet og at EEPROM-er ødelegges av å skrives til for mange ganger (de fleste tåler 10 000 overskrivninger), benyttes EEPROM til oppgaver der man sjelden trenger å endre innholdet.

11.2.5 Flash-minne

Flash har relativt hurtig skriving og billig i forhold til EEPROM. Tåler like mange overskrivninger som EEPROM. Skriving skjer blokkvis, og er derfor egnet når man som oftest bytter ut hele innholdet hver gang man skriver.

11.3 Feilkorrigering i primærlageret

I primærlageret kan det oppstå feil. Disse feilene kan være enten «harde» eller «myke». Harde feil er permanente fysiske feil slik at lagerceller blir upålitelige. Disse feilene kan oppstå ved produksjon, slitasje eller ytre skade. Myke feil er tilfeldige, ikkeødeleggende hendelser som forandrer innholdet til en eller flere lagerceller, uten å ødelegge lageret. Disse feilene kan oppstå ved strømforsyningsproblemer eller pga. alfapartikler (f.eks kosmisk stråling i en satellitt).


Feil vil det alltid være, men det er mulig å bruke feilkorrigerende kode for å finne og/eller rette de opp.

Figur 11.3 over viser hvordan en generell feilkorrigerende kode fungerer. Når et dataord skrives til lageret utføres en funksjon f på dataordet, med en kode som resultat. Både dataord (M) og kode (K) blir lagret. Når ordet blir lest ut bruker man koden til å sjekke om det har oppstått en feil og muligens rette den. I sammenlikningsprosessen ender man opp med et av disse resultatene:

- Ingen feil er detektert, send data ut
- En feil er detektert og det er mulig å rette den, send korrigert data ut
- En feil er detektert, men kan ikke rettes, send feilsignal

11.3.1 Hammingkode

Den enkleste feilkorrigerende koden er *Hammingkoding*. Figur 11.4 under viser hvordan Hammingkoding fungerer for et 4-bits ord.



Figur 11.4: Hammingkode

# databit	Enkeltfeil-korrigering		Enkeltfeil-korrigering + Dobbeltfeil-deteksjon	
	# sjekkbit	% ekstra	# sjekkbit	% ekstra
8	4	50,00	5	62,50
16	5	31,25	6	37,50
32	6	18,75	7	21,88
64	7	10,94	8	12,50
128	8	6,25	9	7,03
256	9	3,52	10	3,91

Tabell 11.1: Kostnad ved bruk av feilkorrigerende kode

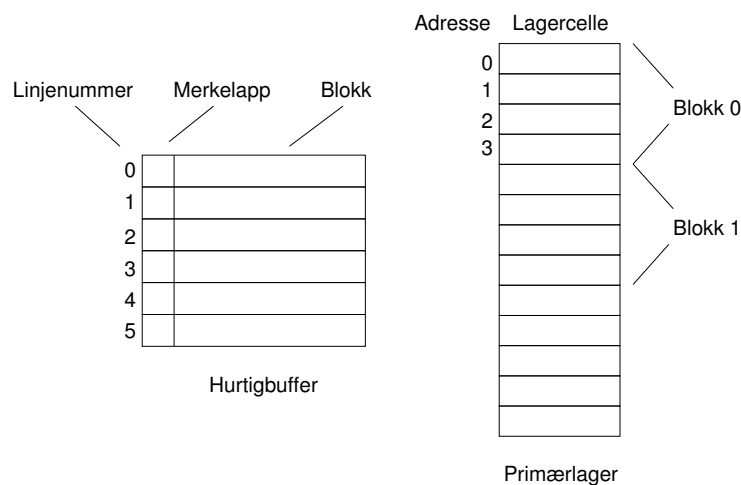
Figur a) viser plassering av de fire databitene.

Figur b) viser de innsatte paritetsbitene. Hver sirkel skal ha et like antall bits som er 1. Det medfører at dersom det er et odde antall enere fra før, setter man inn en ekstra enere i sirkelen. Er det allerede et like antall enere, setter man inn en bit med verdien null.

Figur c) viser dataordet etter at det har oppstått en feil

Figur d) viser at feilen er detektert. Ved å se på paritetsbiten i sirkel A ser man at det har oppstått en feil; det er ikke lenger et like antall enere i denne sirkelen. Det samme gjelder sirkel C, men sirkel B er riktig. Siden den skraverte ruten er den eneste som både A og C deler og ikke B, må det være dette databitet som er feil.

Tabell 11.1 viser kostnad ved bruk av feilkorrigerende kode.



Figur 11.5: Hurtigbuffer

11.4 Hurtigbuffer

Hurtigbufferet (eng: cache) befinner seg mellom prosessoren og primærlageret. Når prosessoren skal hente data fra lageret gjør den oppslag i hurtigbufferet. Hurtigbufferet er mye mindre enn den totale lagerstørrelsen og inneholder derfor bare en liten delmengde av det som finnes i primærlageret. Dersom hurtigbufferet ikke inneholder de aktuelle data sørger hurtigbufferet for å kopiere disse fra primærlageret og inn i hurtigbufferet.

Hensikten med dette er å øke hastigheten på lagertilgang. Hastigheten øker fordi hurtigbufferet er mye raskere enn primærlageret, og de fleste lageraksesser vil kun gå til hurtigbufferet.

Figur 11.5 viser generelt hvordan primærlageret og hurtigbufferet er organisert.

Primærlageret er delt inn i lagerceller på ett ord hver. Hver lagercelle har en unik adresse. Lagercellene grupperes inn i blokker (f.eks 8 celler i hver blokk).

Hurtigbufferet deles inn i linjer. En linje har plass til en blokk med data. Den inneholder også informasjon om hvilken blokk den inneholder (merkelappen).

Prosessoren henter alltid data fra hurtigbufferet og aldri direkte fra primærlageret. Når prosessoren forespør en datablokk som ikke finnes i hurtigbufferet må blokken kopieres fra lageret til hurtigbufferet. Siden det er færre hurtigbufferlinjer enn blokker i lageret, trenger man en algoritme som forteller hvilken hurtigbufferlinje man skal kopiere blokken til. Dette kalles *avbildningsfunksjon*.

Valg av avbildningsfunksjon bestemmer hvordan hurtigbufferet er organisert. Det finnes tre vanlige typer: Direkteavbildning, assosiativ avbildning og sett-assosiativ avbildning.

11.4.1 Direkteavbildning

Direkteavbildning avbilder hver blokk i primærlageret inn i en gitt hurtigbufferlinje. Hver gang denne blokken blir kopiert inn i hurtigbufferet vil den bli plassert på akkurat den samme hurtigbufferlinjen som sist.

Avbildningen skjer slik:

$\text{hurtigbufferlinjenummer} = \text{lagerblokknummer} \% M$

hvor % er modulo-operatoren og M er totalt antall linjer i hurtigbufferet.

Merkelappen til hurtigbufferlinjen settes til blokknummeret for å unikt identifisere hvilken blokk som er lagret.

Direkte avbildning er enkelt og ikke dyrt å implementere, men lite fleksibelt siden den har gitte plasser for alle lagerblokker. Hvis prosessoren hele tiden bytter mellom to minneblokker og de har samme hurtigbufferlinje, må man hele tiden bytte ut innholdet av denne linjen, selv om resten av hurtigbufferlinjene er tomme.

11.4.2 Assosiativ avbildning

Assosiativ avbildning tar høyde for ulempene med direkteavbildning ved å tillate å la alle blokker bli lastet inn på en hvilken som helst hurtigbufferlinje.

Når en blokk skal buffres sjekkes først om den ligger i hurtigbufferet fra før ved å sjekke alle merkelappene. Gjør den ikke det vil den bli lagt i en hvilken som helst hurtigbufferlinje (helst en som er ledig eller lite brukt). Deretter oppdateres linjens merkelapp med riktig blokknummer.

Ulempen med assosiativ avbildning er at den trenger kompleks og dyr (dvs. plasskrevende) logikk.

11.4.3 Sett-assosiativ avbildning

Sett-assosiativ avbildning er et kompromiss av de overnevnte, og inneholder egenskaper ved både direkteavbildning og assosiativ avbildning.

I dette tilfellet er hurtigbufferet delt inn i v sett som hver består av k linjer. Totalt antall linjer i hurtigbufferet (M) blir da:

$$M = v * k$$

En gitt blokk vil avbildes direkte inn i et gitt sett. Blokknummeret vil altså entydig spesifisere hvilket sett som skal benyttes i hurtigbufferet. Avbildning inn i en gitt settlinje er derimot assosiativ, så en gitt blokk kan legges i en hvilken som helst linje innen det gitte settet.

11.4.4 Organisering

Da man begynte å bruke hurtigbuffer hadde man bare et enkelt hurtigbuffer. I senere tid har det blitt vanlig med flere nivå med hurtigbuffer. Man har flere nivå fordi man ønsker å ha høy hastighet og høy treffrate. Begge disse faktorene er avhengig av størrelsen på hurtigbufferet og det er ikke så lett å få begge kravene oppfylt i et og samme hurtigbuffer. Løsningen på problemet er blitt at man har to nivåer. Nivå 1 som er lite og raskt og nivå 2 som er stort (høy treffrate) og «tregt», men likevel raskere en primærlageret.

Før var det vanlig å lagre instruksjoner og data i samme hurtigbuffer. Fordelen med felles hurtigbuffer for instruksjoner og data er at man kan få høyere treffrate og det er enkelt. Nå er det mer vanlig å separere instruksjoner og data inn i hvert sitt hurtigbuffer. Fordelen med separate hurtigbuffer er at man får færre kollisjoner. For å få fordeler fra begge organiseringsmåtene er det vanlig å ha nivå 1 separert og nivå 2 felles.

11.5 Mer om hurtigbufferet

11.5.1 Erstatningsalgoritmer for hurtigbufferet

Når en ny blokk blir satt inn i hurtigbufferet må en av de eksisterende ut. For direkteavbildning er blokken som må ut gitt på forhånd, men for assosiativ avbildning trenger man en erstatningsalgoritme. Fire vanlige algoritmer er:

- *LRU* (least recently used): Bytter ut den blokken som det er lengst tid siden har blitt brukt.
- *FIFO* (first-in-first-out): Bytt ut den blokken som har vært i hurtigbufferet lengst, uavhengig av hvor ofte den har blitt brukt.
- *LFU* (least frequently used): Bytt ut den blokken som har blitt brukt minst.
- *Random*: Velg en tilfeldig linje som skal byttes ut.

11.5.2 Skrivestrategi

Prosessoren skriver nye data til hurtigbufferet. Hvordan skal man sørge for å holde hovedlageret oppdatert med de nye dataene? Det finnes to strategier for å løse dette:


- Gjennomskrivning (eng: write through): Hver gang data endres i hurtigbufferet skrives de samme data tilbake til hovedlageret slik at hurtigbuffer og hovedlager til enhver tid er likt.
- Utsatt tilbakeskriving (eng: write back): Data kan endres i hurtigbufferet uten at hovedlageret oppdateres med de nye data. Hovedlageret oppdateres kun når en blokk i hurtigbufferet skal skiftes ut.

Fordelen med gjennomskrivning er at man er garantert at hovedlageret alltid inneholder gyldige data (dvs. samme data som i hurtigbufferet). Ulempen er at man må gjøre oppslag i hovedlageret hver gang man skal skrive en verdi, noe som går tregt.


Fordelen med utsatt tilbakeskriving er at man slipper å gjøre oppslag i hovedlageret hver gang man skriver en verdi. Ulempen er at hovedlageret og hurtigbuffer kan inneholde forskjellige verdier. Utskiftning av blokker i hurtigbufferet medfører derfor sjekk på om blokken som skal skiftes ut er forandret, og isåfall skrives denne tilbake til primærlageret før den slettes. Dette skaper også problemer i datamaskiner der andre enheter har tilgang til primærlageret (DMA) f.eks fordi disse kan endre primærlageret uten å endre tilsvarende i hurtigbufferet.

11.6 Primærlageret

Primærlageret, eller hovedlageret, er det største direkte adresserbare lageret i datamaskinen. Over dette nivået i lagerhierarkiet finner vi hurtigbufferet. Under dette nivået i lagerhierarkiet finner vi eksternt lageret, som bare kan benyttes i lagerhierarkiet dersom man har operativsystemstøtte for dette.



Figur 11.6: Lagercelle



Figur 11.7: DIMM-kort

Basiselementet til et lager er lagerceller. Typiske egenskaper ved lagerceller er:

- De har to stabile tilstander, som kan bli brukt til å representere 0 og 1 (en bit).
- Man kan skrive til en celle minst en gang for å sette tilstanden.
- Det er mulig å lese cellene for å finne tilstanden.

Primærlageret består hovedsaklig av RAM (Random Access Memory). I noen systemer er det også naturlig å definere ROM (Read Only Memory) som en del av primærlageret. Både RAM og ROM er «random aksess», som vil si at man har direkte tilgang til hele lageret. Du vil få lære mer om RAM og ROM senere.


Figur 11.7 viser et eksempel på et DIMM-kort (Dual In-line Memory Module) som er en vanlig minnebrikke i PC-er. Denne finner du på hovedkortet i nærheten av prosessoren.

11.7 RAM

RAM (Random Access Memory) er en lagerteknologi som det er mulig å både lese fra og skrive til elektronisk. En annen egenskap ved RAM er at den er flyktig, det vil si at strømmen må være på for at innholdet skal bli bevart. De to hovedtypene RAM er statisk RAM og dynamisk RAM.

11.7.1 Statisk RAM

Statisk RAM består av matriser av vipper, der hver vippe (består av 4-6 transistorer) utgjør en celle (bit). SRAM-celler vil bevare sin verdi så lenge strømmen er på.



Figur 11.8: DRAM celle

Fordelen med SRAM er at det er raskt. Ulempen er at det er dyrt (dvs. plasskrevende). SRAM brukes bl.a i hurtigbuffer.

11.7.2 Dynamisk RAM

Dynamisk RAM (DRAM) er laget av celler som består av en transistor og en kondensator. Cellene lagrer data som ladning på kondensatoren. Er ladningen over en viss verdi vil det bli tolket som 1, ellers 0. Kondensatorer lades ut over tid, noe som gjør at DRAM krever periodisk oppfriskning av kondensatorladningen for ikke å miste data.

Fordelen til DRAM er at det er billig (dvs. tar liten plass). Ulemper er lav hastighet og at datamaskinen må oppfriske innholdet hele tiden.

Bruksområdet til DRAM er bl.a primærlager i PC-er.


Figur 11.8 viser hvordan DRAM er bygget opp, mens Figur 11.9 SRAM sin oppbygning. Figurene er tatt med for å illustrere forskjellen i størrelse på celler i de to lagertypene.

11.7.3 Synkron DRAM

DRAM har blitt videreutviklet til *synkron DRAM* (SDRAM), fordi man ønsker en høyere ytelse i primærminne.

Vanlig DRAM er asynkron, og gir ut data så snart den har de klare. Prosessoren må vente til data er klare, og bussen er opptatt helt til overføringen er ferdig.

SDRAM er synkron, noe som vil si at den er styrt av klokkesignalet på systembussen. Når prosessoren ber om data, vil SDRAM svare etter et gitt antall sykler. I mellomtiden kan prosessoren fortsette med andre ting, og systembussen er ledig til annet bruk. Dette gjør SDRAM til den mest vanlige formen for dynamisk RAM i moderne PC-er.



Figur 11.9: SRAM celle

Kapittel 12

Sekundærlager

12.1 Sekundærlageroversikt

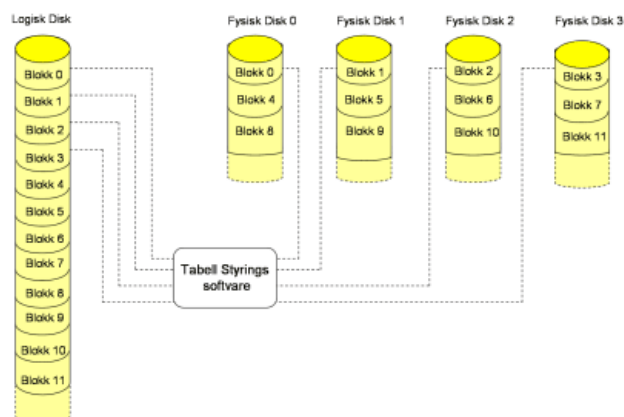
Sekundærlageret (også kalt eksternlageret) er nivået lengst borte fra prosessoren i lagerhierarkiet. Typiske egenskaper ved sekundærlageret er:

- Trenger operativsystemstøtte. Det er programvare som sørger for å kopiere data mellom sekundærlager og internlager.
- Data blir bevart selv om man skur av strømmen.
- Har stor lagringskapasitet.
- Har flyttbar informasjon, dvs. at man kan fysisk flytte lagringsenheten fra en maskin til en annen og informasjonen vil være bevart.
- Er tregt i forhold til resten av datamaskinen.
- Er relativt billig.
- Blir brukt til langtidslagring.

Vi har ulike typer sekundærlager. Her er noen

- Magnetiske medier, platelager (disk):
 - Harddisk
 - Diskett
 - Zip disk
- Diverse typer magnetbånd (tape)
- Optisk disk
 - CD (CD-ROM, CD-R, CD-RW)
 - DVD (DVD-ROM, DVD+R, DVD+RW, DVD-R, DVD-RW, DVD-RAM)

Fysisk sett ligger ikke sekundærlageret på hovedkortet men i egne avtagbare enheter som kobles til hovedkortet (eller til kontrollerkort tilkoblet hovedkortet).



Figur 12.1: RAID

12.2 RAID

RAID står for «Redundant Array of Independent Disks». Opprinnelig sto det for «Redundant Array of Inexpensive Disks», fordi RAID var en måte å benytte billige og upålitelige harddisker til kritiske oppgaver. Nå er alle disker billige og man syntes derfor at RAID trengte en ny betydning.

RAID er å sette sammen flere uavhengige harddisker slik at de oppfattes som en enkelt harddisk for operativsystemet. Det er flere grunner til at man ønsker dette. Man kan ønske å øke hastigheten på dataoverføring ved å spre data over flere harddisker, eller man kan ønske å lagre samme informasjon på flere harddisker for å kunne gjenopprette data hvis en harddisk går i stykker.

RAID har disse karakteristikene:

- Flere fysiske harddisker koblet sammen slik at de oppfører seg som en enkelt harddisk
- Data er spredt ut over alle de fysiske harddiskene
- Noe av diskkapasiteten (kan) benyttes til å lagre paritetsinformasjon slik at data kan gjenopprettes i tilfelle en eller flere disker slutter å fungere

Noen RAID-systemer kan gjenopprette data også mens systemet er i drift. Dette gjør RAID mer attraktivt enn (bare) å benytte sikkerhetskopier.


Et eksempel på RAID er vist i figur 12.1. Det finnes fire fysiske harddisker, men operativsystemet ser bare en stor logisk enhet.

12.2.1 RAID-nivå


Det finnes flere typer RAID med forskjellige egenskaper.

RAID-nivå 0

Dette er ikke et «ekte» RAID oppsett fordi man ikke har redundans (=en eller annen form for duplisering av data eller sjekksum). Man kan derfor ikke



Figur 12.2: RAID 5



Figur 12.3: IDI filtjener

gjenopprette data dersom en av harddiskene går i stykker. I RAID-0 er data organisert akkurat som i tegningen over. Ved å spre data utover slik, kan overførings-hastigheten øke betraktelig, fordi alle harddiskene kan lese ut data i parallell.

RAID-nivå 1-6


Benytter redundante diskere til å lagre data på slik at man kan gjenopprette data i tilfelle en av harddiskene skulle gå i stykker. Hvert RAID-nivå løser oppgaven på sin egen måte, og det finnes fordeler og ulemper med hvert nivå. Som eksempel forklarer vi RAID-5, som er det som benyttes ved IDI, NTNU.

RAID-nivå 5

RAID-5 er et oppsett av harddisker laget for å tåle et stort antall I/O-forespørsler, samtidig som den klarer å gjenopprette data dersom en harddisk feiler.

Et RAID-5-oppsett er vist i figur 12.2. Datablokker er spredt utover de tre harddiskene. Harddiskene er uavhengige slik at man kan lese både fra blokk 0 og blokk 1 i parallell. I tillegg finnes det en paritetsblokk pr. harddisk som sørger for at man kan gjenopprette data dersom en av harddiskene går i stykker.

Eksempel på bruk av RAID på IDI er vist i figur 12.3.



Figur 12.4: CDROM

12.3 Optisk plate



12.3.1 CD-ROM

På en CD-ROM (compact disk read-only memory) er data lagret som groper (pits) i en aluminiumsplate og blir lest av med en laserstråle. Data blir lest med konstant lineær hastighet (CLV): platen roterer saktere ved aksess nær kanten av CD-en i forhold til nær sentrum slik at platearealet som passerer forbi lesehodet er lik både ved sentrum og ved kanten. I tillegg er data lagret i en spiral på platen, og ikke i flere separate spor slik som på en magnetplate.


En CD-ROM-plate har en kapasitet på 700MB.

12.3.2 DVD

DVD (Digital Versatile Disk) ligner på CD-ROM både av utseende og oppførsel. Men den lagrer data tettere enn CD-ROM, og har mulighet til å lagre flere lag med data, på begge sider. DVD har kapasitet fra 4,7 GB (1 side, 1 lag) til 17 GB (2 sider, 2 lag). Aksestiden er 150–250 ms.

12.4 Magnetplate

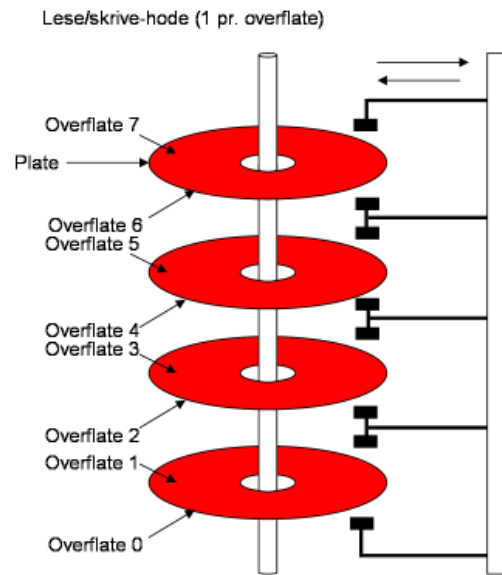
En harddisk består av en sylinder med plater. Hver plate består av flere spor (tracks). Det er like mye data pr. spor. Mellom hvert spor er det mellomrom



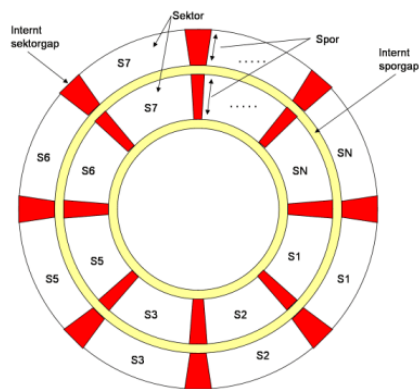
Figur 12.5: DVD



Figur 12.6: Harddisk



Figur 12.7: Hvordan en harddisk ser ut inni



Figur 12.8: Plateutlegg

(gaps) for å unngå feil ved innstilling av lese/skrive-hodet, og for å unngå interferens med det magnetiske feltet. Hvert spor er delt inn i sektorer som inneholder en gitt mengde data (ofte 512 bytes). I tillegg kan vi dele harddisken inn i logiske blokker som er den minste adresserbare enheten på harddisken sett fra operativsystemet. En blokk må inneholde et helt antall sektorer (ofte bare en enkelt sektor).

Mellom platene er det lese- og skrivehoder. Man kan ha et enkelt skrive/lese hode eller de kan være separerte. Ved lesing og skriving er hodet stasjonært og platene roterer.

Bit nær sentrum av den roterende platen passerer et gitt punkt saktere enn bit ytterst på platen. Platen roterer med en konstant vinkelhastighet (CAV) som gjør at sektorer ytterst er fysisk større enn sektorer innerst. Fordelen med CAV er at individuelle blokker kan bli direkte adressert ved spor og sektorer. Ulempen med CAV er at mengden data som kan bli lagret på de ytterste sporene er den samme mengden som det er mulig å lagre på de innerste, og tar dermed opp mer areal enn nødvendig.

For å øke tettheten bruker moderne harddisker «multiple sone recording», som vil si at overflaten blir delt inn i et visst antall soner. De ytterste sonene lagrer mer data pr. spor enn de innerste. Innen en sone er antall bit pr spor konstant.

Når man skal søke etter en gitt blokk finner man først det rette sporet, så venter man på at den rette sektoren skal komme forbi. Kort sagt:

$$\text{Aksesstid} = \text{Søketid (flytte hodet til riktig spor)} + \text{Rotasjonsforsinkelse} + \text{Overføringstid (tiden det tar å overføre dataene)}$$

Man er ikke alltid konsekvent vet definisjonen av aksesstid. Mange lærebøker definerer også denne uten å ta med overføringstid. Vi velger å ta med overføringstiden også da det virker ulogisk å ikke gjøre det.

- Aksesstid: Tid det tar å finne frem til data
- Søketid: Tid det tar å flytte lese/skrive-hodet over til riktig spor
- Rotasjonsforsinkelse: Tid det tar for platen å rotere slik at riktig sektor befinner seg under lese/skrive-hodet

Når man har funnet begynnelsen av sektoren man er ute etter kan man begynne å lese eller skrive.

12.5 Eksempel på beregning av lesetid

En disk består av sektorer og spor. Hvert spor består av flere sektorer. Når man lagrer data på disk ønsker man å lagre data slik at man kan bevege lese- og skrivehode minst mulig under lesing. Den mest optimale måten å lagre på er derfor å først fylle opp en sektor og deretter nabosektoren helt til man har fylt opp et spor. Om filen er for stor til et spor fyller man vider opp nabosporet og deretter naboen til naboen og så videre. Denne lagrings metode fører til at man ikke trenger flytte hode mer en nødvendig.

Når man skal lese filen fra disk må man først finne ut hvor filen starter. Den tiden man bruker til å finne startpunktet til filen kaller vi søketid. Når man har

funnet startsektoren er det bare til å begynne lese spor, først det første sporet og deretter nabosporet. Lese- og skrivehode vil bevege seg minimalt etter som man leser sporene fordi man trenger bare å flytte hode til nabosporet. Denne forskyvingen av hode tar så og si null tid. Disken vil lese et spor pr. runde.

Hvor lang tid det tar å lese en fil er avhengig av hvor fort disken roterer, antall byte pr. spor, søketid og hvor stor filen er.

For å illustrere hvordan man beregner lesetid fra disk skal vi bruke et eksempel. Anta at man har en disk med 90 sektorer pr. spor og hver sektor kan inneholde opptil 200 byte. Disken roterer med en fart på 7000 omdreininger pr. minutt og søketiden er 5.5 ms. Man skal i denne oppgaven finne ut hvor lang tid det tar å lese en fil på 100 MB.

- *Først beregner vi antall byte pr. spor:*

Bytes pr. spor = sektorer pr. spor · bytes pr. sektor

Bytes pr. spor = 90 sektorer · 200 bytes = 18000 bytes

- *Nå kan vi beregne hvor mange spor man trenger for å lese filen:*

Antall spor man må lese = Filstørrelse / Bytes pr. spor

Antall spor man må lese = 100 MB / 18000 bytes

Antall spor man må lese = 5825,42 spor

- *Da kan vi beregne lesetiden:*

Lesetid = Søketid + antall spor man må lese / omdreininger pr. min

Lesetid = 5,5 ms + 5825,42 / 7000

Lesetid = 50 sekunder

Kapittel 13

Trender og Forskning

13.1 Innvevde systemer

Innvevde systemer (eng: Embedded Systems) er kort forklart datamaskiner som gjør en spesifikk oppgave og er del i et større system.

Ta for eksempel en vaskemaskin. Denne inneholder en liten datamaskin som sørger for å kjøre vaskeprogrammet når du trykker på startknappen. Denne datamaskinen er spesiallaget for denne ene oppgaven og kan ikke brukes til noe annet. Dette i motsetning til en generell datamaskin av typen du sitter foran nå.

Innvevde systemer finnes overalt og er faktisk den aller vanligste formen for datamaskiner, selv om man ikke alltid forbinder de med det. Her er en liste over typiske, hverdagslige ting som ofte inneholder prosessorer:

- Vaskemaskiner, tørketromler
- Klokker
- Minibanker
- Mobiltelefoner
- Biler (ABS-bremsesystem, innsprøytningssystem, etc.)
- Fjernsynsapparater
- Termostater

Innvevde systemer spesiallages for en spesiell oppgave. Design av slike systemer vil som oftest bestå i utvikling av både maskinvare og programvare. Dette gjør innvevde systemer til en veldig heterogen gruppe med datamaskiner.

13.1.1 Designhensyn

Utvikling av innvevde systemer har ofte helt andre designkrav enn for andre typer datamaskiner.

Kostnad

Mange av disse systemene er hverdagslige ting der kostnad spiller en vesentlig rolle. Totale produksjonskostnader bør derfor være så små som mulig.

Strømforbruk

Portable enheter (f.eks mobiltelefoner) må trekke strøm fra et batteri. Man ønsker maksimal batterilevetid, og strømforbruket til enheten må derfor være så liten som mulig.

Sanntid

Mange innvevde systemer har sanntidskrav. Et sanntidssystem er et system som garantert svarer innen det har gått en viss tid. En vanlig PC har ikke slike garantier, og man vil kunne oppleve at maskinen «henger» noen sekunder fordi den jobber tungt. Et sanntidssystem garanterer at den oppfyller visse krav om responsivitet.

F.eks ønsker man ikke at stabilisatorsystemet på et jagerfly plutselig «henger» noen sekunder. Det kan være nok til å sende flyet i bakken.

Levetid

Slike systemer er ofte i bruk i lang tid, og må derfor bygges for å vare. Systemet må være driftssikkert. Det er ikke utenkelig med levetid på 20 år eller mer.

Størrelse og vekt

Fysisk størrelse er viktig. F.eks må en mobiltelefon være så liten og lett som mulig.

Vanskelig miljø

Av og til skal systemet inn i et miljø som stiller spesielle krav til elektronikken. Dette kan være ekstrem varme, kulde, stråling og risting. Blant annet satellitter må ta hensyn til slike ting.

Hastighet

Hastighet er ofte *ikke* viktig for et innvevd system. En vaskemaskin trenger ikke all verdens med datakraft for å kjøre vaskeprogrammet.

13.1.2 Komponenter - Mikrokontroller

Den viktigste komponenten i et innvevd system er som i alle andre datamaskiner: prosessoren. Men det er ikke så vanlig å benytte en prosessor av den typen som sitter i en PC. I stedet bruker man en *mikrokontroller*. Dette er en liten mikrobrikke som inneholder prosessor men som i tillegg inneholder de andre viktigste komponentene en datamaskin trenger: I/O-moduler, RAM, ROM (og ofte Flash), timere etc. Man kan si at en mikrokontroller er en hel datamaskin på én brikke. Det finnes en lang rekke forskjellige mikrokontrollere på markedet,

som ikke er like ensrettet som prosessormarkedet i PC-industrien der Intel-arkitekturen dominerer.

Fordelene med å benytte en mikrokontroller fremfor en vanlig prosessor:

- Mindre fysisk; én brikke erstatter mange
- Bruker mindre strøm
- Enkelt, man har det meste man trenger på én brikke noe som gjør det enkelt å bygge et system rundt
- Laget spesielt med tanke på enkel utvikling av innvevde systemer

En typisk mikrokontroller er svært mye mindre kraftig enn en vanlig PC. Prosessorene er ofte på 8-bit. Klokkefrekvenser er ofte fra 1MHz og oppover. RAM-størrelse kan være fra 1kB og oppover (ingen cache), og ROM er ofte den største delen av det adresserbare lageret.

Dette er nesten ufattelig små verdier for en som er vant til dagens PC-er, men er nok for de aller fleste dataprosesseringsoppgaver i innvevde systemer. Det er et morsomt faktum at selv i dag er det slike små 8-bits datamaskiner som fremdeles selger mest (på grunn av alle innvevde systemer), selv om de færreste kjenner til noe annet enn de kraftige 32-bits PC-ene som benyttes i dag.

I tillegg til mikrokontrolleren vil man ofte trenge en del komponenter for akkurat den spesielle oppgaven dette systemet skal utføre. Dette kan være sensorer, motorer, nettverkstilkobling etc.

13.1.3 Utvikling


Utvikling av et innvevd system er en spennende oppgave fordi det involverer mange forskjellige ting. Man skal bygge maskinvare som er i stand til å løse et gitt problem, for deretter å programmere den samme maskinvaren. Viktige valg må tas om hva som skal gjøres av maskinvare og hva som skal gjøres av programvare i en mikrokontroller (HW/SW-kodesign).

Utvikling av programvare for et innvevd system er ikke som på en vanlig PC. Programvaren skal kjøre på et lite kretskort ofte uten skjerm, tastatur, operativsystem og andre nyttige ting. Man skriver derfor ikke programvaren på maskinen den skal kjøres på. I stedet skriver man programvaren på en vanlig PC og overfører programvaren til kortet før kjøring. Avlusning av programvare skjer ofte ved hjelp av en såkalt ICE (In Circuit Emulator) som erstatter mikrokontrolleren med en emulatorekrets som gir brukeren mulighet til å styre og kontrollere alt vha. en PC.

13.2 Trender

13.2.1 Moores lov

Utviklingen av integrerte kretser har hatt svært mye å si for datamaskinen slik vi kjenner den. Den første integrerte kretsen ble demonstrert i 1959. Etter dette har det vært en jevn utvikling der antall transistorer pr. arealenheter har økt, fra noen få transistorer på begynnelsen av 60-tallet til millioner av transistorer i dag (42



Figur 13.1: Moores lov

millioner på en Pentium 4). Tettheten av transistorer har økt så jevnt at dette har blitt formulert som en lovmessighet. Gordon Moore, en av grunnleggerne til Intel, formulerte allerede i 1965 en lov som senere har blitt kalt Moores lov: Antall transistorer det er plass til på en brikke fordobler seg for hvert år. Til alles forundring har denne loven vist seg å stemme svært godt. Etter 1970 sakk hastigheten på utviklingen litt ned slik at Moores lov ble omformulert slik:

Moores lov: Antall transistorer det er plass til på en brikke fordobler seg hver 18. måned.


Denne utviklingen har holdt helt frem til i dag. Dette vises i figur 13.1 som er en oversikt over antall transistorer (y-aksen) i Intel-prosessorer siden 1970.

Moores lov har en rekke interessante konsekvenser:

- Prisen pr. databrikke har vært noenlunde konstant siden starten. Dette medfører at prisen på logiske kretser og datalager (regnet pr. byte) har gått ned dramatisk i takt med Moores lov.
- Høyere tetthet på brikken medfører kortere signalvei og dermed høyere hastighet.
- Datamaskiner blir mindre.
- Mer logikk på hver brikke medfører færre brikker totalt pr. datamaskin. Det er gunstig både med hensyn på pris og med hensyn på driftsikkerhet.

Tilsvarende utvikling har vi for hastigheten til kritiske komponenter i datamaskinen. Figur 13.2 vises en oversikt over utviklingen til prosessor- og DRAM-hastighet.

Her ser vi et problem: Prosessorhastigheten øker svært mye raskere enn DRAM-hastigheten. Vi får med andre ord et stadig større gap mellom hvor fort prosessoren prosesserer data og hvor fort primærlageret kan levere data. Dette har vi delvis løst i dag med større lagerhierarki (hurtigbuffer) og bredere databusser, men problemet vil bare bli større i fremtiden.



Figur 13.2: Utvikling til prosessor og DRAM-hastighet

13.2.2 Nærmer Moores lov seg slutten?

Moores lov har vist seg å stemme godt siden den ble formulert. Vil dette fortsette i det uendelige?


De fleste er enige om at vi snart vil nå en grense for hvor tett vi klarer å pakke transistorene sammen. Det er flere grunner til det. En av de er visualisert i figur 13.3. Vi ser der et tid/effekt-diagram der vi har plottet inn Intel-prosessorer. Vi ser at effekten (utstrålt som varme) fra en cm^2 prosessor de siste år har økt kraftig. Det er ventet at dette vil fortsette når antall transistorer pr. cm^2 øker, noe som vil bli et stort problem. Varmen på en prosessor nærmer seg allerede varmen fra en kokeplate og krever derfor kraftig nedkjøling for å virke. Dersom Moores lov fortsetter vil forventet varmestråling fra prosessoren tilsvare solens overflate om få tiår. Dette vil bli umulig å kjøle ned til normale temperaturer.

13.3 Biologisk inspirasjon


The best way to predict the future is to invent it. – Alan Kay

Det er mer enn et snev sannhet i Alans betraktning om hvordan man kan spå fremtiden. Som kommende ingeniører vil dere selv delta i det å forme fremtiden. Alan selv var med på å utforme Smalltalk, et objektorientert programmeringsspråk. Ved Xerox var han også sentral i utformingen av vindu-baserte grafiske grensesnitt

I dag forskes det på IKT på alle mulige nivå, fra kvantemekanisk- og nanonivå og opp til systemnivå og høynivå modellering. Fra tidligere rom har dere lært om trender i utviklingen og Moore's Law. Men det finnes en grense for hvor langt vi kan komme med dagens teknologier og teknikker. Et forskningsområde som kan finne nye løsninger innen IKT er biologisk-inspirerte systemer.



Figur 13.3: Tid/effekt-diagram for Intel-prosessorer




Figur 13.4: Phylogeny, Ontogeny and Epigenesis

13.3.1 Biologisk inspirerte systemer

Bioinspirerte systemer benytter teknikker inspirert av de fenomener vi kan observere i biologiske systemer. Mange biologiske systemer har egenskaper helt ulike de vi i dag er i stand til å oppnå med datamaskiner. Eksempelvis kan biologiske vesener utføre mange intelligente oppgaver som maskiner ikke er i stand til i dag. Mest fasinende er kanskje menneskers evne til å lære og tilpasse seg omgivelsene. Men også enkle organismer har egenskaper som er ettertraktet i datamaskiner. Datamaskiner i dag er for eksempel veldig sårbare for feil. Ofte kan en enkelt ødelagt transistor medføre at en hel datamaskin slutter å fungere. På samme måte kan en enkelt feil i prosessorkonstruksjonen vår eller en liten feil i et program være nok til at maskinen blir ubrukelig. I biologien kan feil være like kritisk, men veldig ofte vil slike enkeltfeil ikke påvirke systemet.

Mange bioinspirerte teknikker kan klassifiseres i POE-modellen (se figur 13.4). Bortsett fra de mest primitive organismene, vil de fleste organismer i naturen utvikle seg langs alle de tre aksene; evolusjon, utviklingsprosess og læring.



Figur 13.5: Evolusjon av mennesket (Phylogeny) [David Gifford/Science Photo Library]

Phylogeny (fylogeni)

Med fylogeni menes her evolusjon over generasjoner (Darwinisme). Genene våre er stort sett det eneste som arves fra ens forfedere rent fysiologisk.

Bioinspirerte teknikker i denne kategorien omfatter bruk av *kunstig evolusjon*. Genetiske algoritmer og genetisk programmering er to slike teknikker. For å lære litt mer om hvordan kunstig evolusjon fungerer i praksis finnes det en grei introduksjon til genetiske algoritmer her: <http://cs.felk.cvut.cz/~xobitko/ga>. Genetiske algoritmer jobber gjerne på linære strenger. Genetisk programmering derimot brukes gjerne om kunstig evolusjon av trestrukturer (for eksempel programtrær). Genetisk programmering kan blant annet benyttes til å løse travelling salesman-problemet (<http://www.evonet.polytechnique.fr/CIRCUS2/node.php?node=81>) og symbolsk regresjon (<http://www.evonet.polytechnique.fr/CIRCUS2/node.php?node=56>)

Ontogeny (ontogeni)

Ontogeni omfatter her utviklingsprosessen fra embryo til en fullvoksen organisme. Dette skjer ved celledeling. Cellene differensierer seg og begynner å spesialisere seg avhengig av hvilke funksjoner de skal ha i organismen. Etterhvert begynner organismen å ta form og tilslutt vokse til et fullvoksnet individ.

Systemer som utvikler seg og kan reproducere seg klassifiseres under ontogeni. Innen ontogeni er cellulære automater ofte benyttet, et system organisert som celler i et regulært rutenett. Regler styrer hvordan rutenettet utvikles. I bioinspirert sammenheng kan disse reglene sees på som et slags DNA, enkle rettningslinjer som kan gi komplekse resultater. Et velkjent eksempel på en slik cellulær automat er Game of life (<http://www.math.com/students/wonders/life/life.html>)

Epigenesis (epigenese)

Epigenese omfatter i denne forbindelse læringen i løpet av et individs levetid. Tre eksempler på lærende systemer i menneskekroppen er nervesystemet, immunsystemet og endokrinsystemet (hormoner).



Figur 13.6: Utviklingsprosessen fra en befruktet eggcelle (Ontogeny) [Dr. G. Moscoso/Science Photo Library]

Lærende systemer som nevralt nettverk og kunstige immunsystemer havner under epigenese. Nevrale nettverk etterligner vår forståelse av menneskets hjerne. Generelt kan man si at et nevralt nettverk består av neuroner som endrer sin utgang dersom den blir utsatt for et gitt sett av inngangssignaler. Således kan et nevralt nettverk produsere spesifikke utgangssignaler avhengig av inngangssignaler. Nettene kan også lære, for eksempel ved en justering av feil i utgangssignalet propageres tilbake igjennom nodene i nettet. Nevrale nettverk har etter hvert funnet mange bruksområder innen IKT, for eksempel prosessmodellering og prosesskontroll, investering og finansapplikasjoner, bilde- og stemmegjenkjenning, medisinsk diagnose, målrettet markedsføring og datasøk.

Noen systemer kombinerer også flere bioinspirerte metoder, og kan da ha egenskaper langs flere eller alle aksene i figur 13.4. For eksempel så kan man evolvere frem (tilkoblingene eller vektene i) nevralt nettverk.

Det du nå har lært om biologisk-inspirerte metoder har kanskje ikke gitt deg detaljkunnskap, men heller en liten oversikt over hva som finnes av metoder som du kanskje vil møte senere i studiet.




Figur 13.7: Et menneskelig neuron som «kan lære» (Epigenesis) [Science Photo Library]

Kapittel 14

Oppsummering

14.1 Oppsummering: Hurtigbuffer



Hurtigbufferet er den delen av lagerhierarkiet som ligger mellom registrene på toppen og primærlageret. Hurtigbufferet er altså mindre og raskere enn primærlageret og brukes til å øke hastigheten på lageraksesser.

Det finnes ofte to hurtigbuffer i lagerhierarkiet; hurtigbuffer nivå 1 og nivå 2. Nivå 1 er det minste og raskeste og bufret data fra nivå 2. Nivå 2 er litt større og tregere og bufret data fra primærlageret.

Hurtigbufferet deles inn i linjer som hver inneholder en merkelapp som sier hvilken adresse som er bufret i denne linjen og et dataområde med data fra denne adressen. I tillegg finnes blant annet informasjon om data er gyldig eller ikke.

Når prosessoren gjør en lageraksess til en adresse som ikke er bufret vil hurtigbufferet hente data fra nivået under i lagerhierarkiet. Dette vil den plassere i hurtigbufferet, enten ved hjelp av direkte, assosiativ eller sett-assosiativ avbildning.


Brukes en form for assosiativ avbildning må det finnes en måte å bestemme hvilken linje i hurtigbufferen man skal skifte ut når nye data skal bufres. Dette gjøres med en erstatningsalgoritme. Denne kan være LFU (Least Frequently Used), FIFO (First In First Out), LRU (Least Recently Used) eller tilfeldig.

Hurtigbufferet inneholder en kopi av data fra lavere nivå i lagerhierarkiet. Derfor må data som oppdateres i hurtigbufferet også skrives tilbake til de lavere nivå for at de ikke skal gå tapt. Det finnes to tilbakeskrivingsstrategier: Gjennomskrivning (data skrives tilbake med en gang de oppdateres i hurtigbufferet) og utsatt tilbakeskriving (data skrives kun tilbake når hurtigbufferlinjen skal erstattes med en annen adresse).

Her er en liste over viktige stikkord:

- Avbildningsfunksjon
 - Direkteavbildning
 - Assosiativ avbildning
 - Sett-assosiativ avbildning
- Erstatningsalgoritmer
 - LRU
 - FIFO
 - LFU
 - Tilfeldig
- Skrivestrategi
 - Gjennomskrivning
 - Utsatt tilbakeskriving

14.2 Oppsummering: Prosessoren



Prosessoren slik den er i dag følger en modell beskrevet av von Neumann i 1945. Dette vil i hovedsak si at datalageret inneholder både instruksjoner og data. Instruksjoner mates inn i prosessoren som da utfører en operasjon på data.

Ofte deles prosessoren inn i en styreenhet og en utførende enhet. Den utførende enheten gjør selve dataprosesseringen, mens styreenheten dekoder instruksjoner og setter opp utførende enhet til å gjøre riktig operasjon.

Utførende enhet består av en registerblokk der midlertidige data lagres og en aritmetisk-logisk enhet (ALU) som utfører aritmetiske og logiske operasjoner. Den utførende enheten styres av et styreord som settes opp av styreenheten. Styreordet inneholder alle nødvendige styresignaler.

I tillegg til registerblokken finnes det noen spesialregistre. De viktigste er programtelleren (PC), instruksjonsregisteret (IR) og statusregisteret (SR). PC inneholder til enhver tid adressen til neste instruksjon som skal utføres. IR inneholder instruksjonen som er under utførelse. SR inneholder informasjon om tilstanden til prosessoren, informasjon som benyttes blant annet til betingete hopp.

Instruksjonsutføring deles inn i flere steg; det som kalles instruksjonssykel. Instruksjonssykel kan implementeres ved hjelp av en tilstandsmaskin eller ved hjelp av et samlebånd. Samlebånd lar flere instruksjoner kjøre samtidig med

hverandre men i hver sitt steg i instruksjonssykelen. Dette øker hastigheten. Problemer er hoppinstruksjoner og dataavhengigheter.

Her er en liste over viktige stikkord:

- von Neumann-arkitektur
- mikrooperasjoner
- prosessoren, introduksjon
- utførende enhet
 - ALU
 - registerblokk
 - styreord
- PC, SR, IR
- styreenhet
- instruksjonssykel
- samlebånd
 - dataavhengigheter
 - håndtering av forgreninger (hopp)
- RISC/CISC
- big/little endian

14.3 Oppsummering: Instruksjoner

```
add $1, $2, $3  
jmp loop
```

Prosessoren er avhengig av å få tilført en jevn strøm av instruksjoner slik at den vet hva den skal gjøre. Det er prosessorarkitekturen som dikterer hvilke instruksjoner som finnes.

Instruksjonssettet består av alle instruksjoner en gitt prosessor kan utføre. Det finnes mange typer instruksjoner; dataoverføring, aritmetiske, logiske, konvertering, I/O, systemkontroll og kontrollflyt.

Hver instruksjon tar et antall operander, ofte fra ingen operander til tre operander. Stakkmaskininstruksjoner tar ofte ingen operander, stakken er implisitt operandkilden. Load/Store-maskininstruksjoner tar ofte tre operander; destinasjon, argument A og argument B.

Assemblyprogrammering er programmering på laveste nivå. Her spesifiseres direkte hvilke instruksjoner prosessoren skal utføre.


Hver operand angir hvor data til en instruksjon befinner seg. Dette kan angis på flere forskjellige måter og kalles operandens adresseringsmodus. Dere har lært disse: immediate, direkte, indirekte, register, indirekte register, displacement (og indeksering) og stakk.

Instruksjoner består av et gitt antall bit; et instruksjonsord. Instruksjonsordet består av en rekke felter som definerer instruksjonen. De viktigste er opkode som forteller hva denne instruksjonen skal gjøre (JUMP, ADD etc.) og operandfelter som angir hvor operandene finnes.

Her er en liste over viktige stikkord:

- Instruksjonssett
- Assembly
- Antall operander
- Load/Store-maskin
- Adresseringsmodi
- Instruksjonsformat

14.4 Oppsummering: Primærlageret



Primærlageret er den nederste delen av lagerhierarkiet som har automatisk (maskinvarestyrt) støtte. Det er primærlageret prosessoren «ser» når den gjør lageraksesser. Hurtigbufferet som prosessoren egentlig gjør en aksess til fungerer transparent for prosessoren slik at prosessoren ikke trenger å vite at det ikke er det egentlige primærlageret den gjør aksesser til.

Primærlageret består hovedsaklig av RAM. I noen systemer kan det også være naturlig å definere ROM som en del av primærlageret.


RAM er et flyktig lager som kan skrives til og leses fra. Det finnes hovedsaklig to typer: Statisk og dynamisk RAM. Statisk RAM tar størst plass (flest antall transistorer) men er raskest. Dynamisk RAM tar mindre plass, men benytter kondensatorer til å lagre verdier i. Den må derfor oppfriskes jenvlig for ikke å miste data.

ROM er et lager man bare kan lese fra (i normal operasjon). Det finnes mange typer: ROM, PROM, EPROM, EEPROM og Flash.

Her er en liste over viktige stikkord:

- Primærlageret
- RAM
 - Statisk RAM (SRAM)
 - Dynamisk RAM (DRAM)
- ROM
- Adressering
- Feilkorrigering

14.5 Oppsummering: Lagerhierarkiet



Alle datamaskiner trenger et lager til data. Konseptuelt sett finnes det bare ett stort lager (i tillegg til registrene). Fysisk er det derimot ordnet på en annen måte.


Et lager kan klassifiseres etter følgende kriterier: Størrelse (lagerkapasitet), hastighet og kostnad. Generelt kan man si at dersom lagerkapasiteten øker går hastigheten ned. Utfordringen ligger derfor i å lage et stort og hurtig lager som ikke koster for mye.

En observasjon ble gjort: Lageraksesser følger noe som kalles «lokalitetsprinsippet». Det vil si at data som nylig er brukt sannsynligvis vil bli brukt igjen snart. Prosessoren jobber altså på et lite sett med data av gangen. Dette kan utnyttes ved å benytte et lagerhierarki. Et stort og tregt lager danner grunnlaget. Men de til enhver tid mest brukte data ligger også lagret i et mindre, hurtigere lager. Slik kan man lage et hierarki der vi har raskt og lite lager på toppen og tregt og stort lager på bunnen. Dette er vist i figuren på toppen. Resultatet blir et lager som er nesten like raskt som lageret øverst i hierarkiet men samtidig like stort som lageret nederst i hierarkiet.

Her er en liste over viktige stikkord:

- Lagerhierarki
- Hastighet vs. størrelse vs. pris
- Lokalitetsprinsippet

14.6 Oppsummering: Primærkunnskaper



Vi bruker vanligvis titallsystemet når vi regner. Men det finnes mange andre tallsystemer i bruk. Et tallsystem defineres av dens base. Viktigst her er totallsystemet (binære tall) der man har base 2, dvs man benytter bare tallene 0 og 1. Totallsystemet er grunnlaget for all regning i en digital datamaskin. I dag benytter vi som oftest toerskomplement til å representere negative binære tall.

Sentrale lagringenheter i et digitalt system er bit, byte og dataord. Kilo i datasammenheng er som oftest er 1024 og ikke 1000.


Flyttall er «kommatall» med eksponent. Disse representeres ofte ved hjelp av IEEE's flyttallsstandard: fortegnsbitt, eksponent (med forskyvning) og signifikand.

Digitale systemer bygges opp av logiske porter. Noen elementære komponenter laget av porter er multipleksere, dekodere og adderere. Synkrone kretser benytter et klokkesignal til å synkronisere alle hendelser med. En viktig synkron komponent er en vippe.

Her er en liste over viktige stikkord:

- Tallsystemer
 - Binære tall
 - Toerskomplement
 - Omregning mellom tallsystemer
 - Bits og bytes, ord
 - Flyttall
- Digitalteknikk
 - Porter
 - Multiplekser
 - Adderer
 - Dekoder
 - Klokkesignal, synkrone kretser, vipper

14.7 Oppsummering: I/O



I/O er kommunikasjon mellom prosessoren og andre enheter (bortsett fra lageraksesser som ikke defineres som I/O). I/O gjøres enten ved hjelp av egne I/O-instruksjoner i prosessoren eller ved at I/O-enheter får en del av adresseområdet (lageravbildet I/O).

Prosessoren kommuniserer nesten aldri direkte med ønsket I/O-enhet. I stedet kommuniserer den med en I/O-kontroller som sitter mellom prosessoren og I/O-enheten. I/O-kontrolleren gir prosessoren et enkelt grensesnitt mot I/O-enheten.

Kommunikasjon med I/O-kontroller kan enten være programmert (polling), avbruddsdrivet eller DMA (Direct Memory Access).

Busser er kommunikasjonsveier mellom enheter. De består ofte av data-linjer, adresselinjer og styrelinjer. Det finnes ofte mange forskjellige busser med forskjellig hastighet i en datamaskin. Bussarkitekturen i en datamaskin settes opp i et hierarki, akkurat som lageret som settes opp i et hierarki fordi forskjellige lagertyper har forskjellig hastighet.

Busser har ofte mange enheter tilknyttet seg. Bare en enhet kan skrive til bussen av gangen. For å styre hvilken enhet som skriver kan en av enhetene være

«herre» som styrer alt som skjer, eller man kan benytte en form for arbitrering; en algoritme (ofte styrt av en arbitreringsenhet) som sørger for å velge ut hvem som får skrive til bussen.

Busser kan enten være synkrone (koordinert av en klokke) eller asynkrone (koordinert med et sett av «håndtrykk»-signaler).

Her er en liste over viktige stikkord:

- Lageravbildet I/O vs. egne I/O-instruksjoner
- I/O-kontroller
- Programmert I/O
- Avbruddsdrevet I/O
- DMA
- Busser
 - Datalinjer, adresselinjer, styrelinjer
 - Busshierarki
 - Bussarbitrering
 - Synkron vs. asynkron buss

14.8 Oppsummering: Sekundærlageret



Sekundærlageret er I/O-enheter som tar seg av lagring av data. Det tilhører de nederste delene av lagerhierarkiet. Siden sekundærlageret er I/O-enheter så vil det i motsetning til primærlageret (og nivåene over det) kreve programvarestøtte for å kunne brukes.

Sekundærlageret består ofte av magnetplater (harddisker og disketter). Harddisker kan settes opp i en konfigurasjon kalt RAID for å øke tilgjengelighet og hastighet.

Harddisker består av flere magnetplater. Hver plate deles inn i spor og sektorer. Hver plateoverflate har et lese/skrive-hode som kan beveges fra et spor til et annet.

Aksesstid = Søketid (flytte hodet til riktig spor) + Rotasjonsforsinkelse +
Overføringstid (tiden det tar å overføre dataene)


Man er ikke alltid konsekvent vet definisjonen av aksestid. Mange lærebøker definerer også denne uten å ta med overføringstid. Vi velger å ta med overføringstiden også da det virker ulogisk å ikke gjøre det.

Det finnes også en del former for optiske medier (CD og DVD).

Her er en liste over viktige stikkord:

- Magnetplate
 - RAID
- Optisk plate
- Konstant vinkelhastighet (CAV) vs. konstant lineær hastighet (CLV)
- Multiple zone recording (MZR)

14.9 Oppsummering: Annet



Innvevde systemer er små datamaskiner spesialbygde for ett spesielt formål. Eksempler er styresystemene i vaskemaskiner og mobiltelefoner.

Innvevde systemer benytter ofte en mikrokontroller. Dette er en hel datamaskin på en enkelt brikke. Dette gjøres for å få systemet fysisk lite, strøm-effektivt og billig. Ofte kan hastighet og datakraft nedprioriteres til fordel for pris, liten størrelse og vekt, lavt strømforbruk og andre faktorer viktige for det spesielle miljøet systemet skal benyttes i.

Moore's lov sier at antall transistorer på en brikke fordobles hver 18. måned. Dette har vist seg å stemme. Dette illustrerer den raske utviklingen innen data-teknologien. Flere barrierer innen brikke-design tyder likevel på at dette vil stoppe opp snart.

Biologisk-inspirerte systemer baserer seg på helt andre teknikker for program- og maskinvareutvikling enn tradisjonelle systemer. Dette kan være interessant for å få til systemer vi ikke klarer å lage med tradisjonelle metoder.

Her er en liste over viktige stikkord:

- Innvevde systemer
- Trender
 - Moore's lov
- Biologisk inspirasjon