

Representasjon av tekst (enkelttegn), Seksjon 4.3  
i komp.

I en datamaskin er alt 0 og 1

Ved hjelp av dette kan vi representere heltall  
og reelle tall (flyttall).

Hvordan kan vi bruke tall til å representere  
tekst?

I en datamaskin representeres enkelttegn ved  
hjelp av heltalls koder og en tabell som  
forteller hvilken heltallskode som svarer til  
hvilket tegn. Ved innlesing oversettes tegnene  
til korrekte koder og ved utskrift skrives  
koderne som riktige tegn.

a-1	b a d
b-2	2 1 4
c-3	
d-4	
e-5	

ASCII - tabellen.

I datamaskinens verden hadde hver leverandør hver sin tekststandard.

ASCII - tabellen ble etter hvert en standard. Første gang publisert i 1963, siste gang oppdatert i 1986.

ASCII består av 128 tegn og kan dermed kodes med 7 bits ( $2^7 = 128$ ).

Etterhvert ble det vanlig å legge til en 0 foran slik at tegne kunne representeres med 1 byte (= 8 bits)

Etterhvert ble det behov for å kunne representere tegn utover de som fins i ASCII.

Med slutt av 80-tallet kom såkalt ISO-Latin tegnsett.

ISO-Latin 1 - vest Europa

ISO-Latin 2 - sentral Europa

ISO-Latin 5 - Tyrkisk.

Alle disse bruker koder med 8 bits som brukes fullt ut, altså  $2^8 = 256$  tegn.

ASCII ligger i de første 128 kodene.

ISO Latin fungerte greit internt i deler av den vestlige verden, men kommunikasjon på tvers av de ulike områdene var stadig vanskelig.

## Unicode.

Man trenger en tabell som kunne inneholde alle verdens tegn. Data selskaper gikk og dannet en organisasjon som het Unicode.

Unicode har koder fra 0 - 1114111 - litt over en million tegn. Men ikke på langt nær alle koder er i bruk (bare ca 100 000 som er i bruk).

Med UTF-32 lagres unicode koder fullt ut. Da trenger vi 4 bytes til hvert tegn. Dette er problematisk for vertlige tekster - en fil tar da opp 4 ganger så mye plass som hvis brukte 150-biter!

Løsning: Man lagrer koder ved hjelp av et variabelt antall bytes.

UTF-8.

Fact 4.10. Hvis koden er

1.  $c = (d_6 d_5 d_4 d_3 d_2 d_1 d_0)_2$  i intervallet  $(0-127)$   
lagres den i en byte som  $65 = 64 + 1$   
 $0 d_6 d_5 d_4 d_3 d_2 d_1 d_0$   $01000001$

2. Hvis  $c = (d_{10} d_9 d_8 d_7 d_6 d_5 d_4 d_3 d_2 d_1 d_0)_2$  er  
i intervallet  $128-2047$  lagres den i 2 bytes  
som  
 $110 d_{10} d_9 d_8 d_7 d_6$   $10 d_5 d_4 d_3 d_2 d_1 d_0$

3. Hvis  $c = (d_{15} d_{14} \dots d_1 d_0)_2$  er i  
intervallet  $2048-65535$  lagres koden som  
 $1110 d_{15} d_{14} d_{13} d_{12}$   $10 d_{11} d_{10} d_9 d_8 d_7 d_6$   $10 d_5 d_4 d_3 d_2 d_1 d_0$

4. Hvis  $c = (d_{20} d_{19} \dots d_0)_2$  er i intervallet  
 $65536-1114111$  lagres med 4 bytes  
 $11110 d_{20} d_{19} d_{18}$   $10 d_{17} d_{16} d_{15} d_{14} d_{13} d_{12}$   $10 d_{11} \dots d_6$   
 $10 d_5 d_4 d_3 d_2 d_1 d_0$

Datamaskinen må til enhver tid  
være i hænderne på dem og i den  
leser skal tolkes!