


Utviklingen av fritekstsystemer

Hovedpunkter for forelesningen


- Litt repetisjon fra 2. time
 - Om støtteundervisning i INF1000
- Ulike typer Fritekstsystemer
- Litt om HTML og XML

DRI 2010 -H09 90909 Arild Jansen , AFIN

Hva er datakommunikasjon - en enkel modell



Ulike lag i en datakommunikasjonsmodell - forenkelt



Hva består en bok av - og hvordan representerer denne

Eksempel på en typisk struktur på en bok

```
graph TD; Bok[Bok] --- Bok-tittel[Bok-tittel]; Bok --- Forord[Forord]; Bok --- Indeks[Indeks]; Bok --- Kapittel[Kapittel]; Bok-tittel --- tekst1((tekst)); Forord --- tekst2((tekst)); Indeks --- tekst3((tekst)); Kapittel --- Tittel[Tittel]; Tittel --- tekst4((tekst)); Kapittel --- Avsnitt[Avsnitt]; Avsnitt --- tekst5((tekst))
```

En bok må kunne beskrives både ved sin layout, sin struktur og sitt innhold !

Hvordan kan beskrive denne strukturen ?

- Bruke "Word-format" (.doc) ?
- Bruke .ODT (open tekst) format?
- Bruke .pdf-format?
- Legge det inn i en (strukturert) database?
- Bruke HTML?
- Andre løsninger?

Et alternativ er **XML** (Extensible Markup Language)
Et annet alternativ er emnekart (Topic Map)

Data og metadata

- **Data** : [Her forstått som] formalisert representasjon av informasjon i en eller annen form (tekst, lyd, bilde). Data kan være fri tekststrenger eller strukturerte data med bestemt formell betydning
- **Dataelement**: Enhet av data som er udelelig, f eks. f. navn, e.navn, p.nr, telefonnr. ...
- **Datadefinisjon**: Type og formatbeskrivelse av et dataelement
- **Metadata** : Data om dataelementer, inkl. datadefinisjon, dataeierskap, tilgangsrettigheter,.....
 - Metadata brukes både i tradisjonelle (relasjons) databaser og andre typer databaser (f eks. i HTML, XML , osv.)

Eksempel :

- Ola Nordmann er født: 05/07/09 : Data(vi tror vi forstår)
- Formater på datoer er med mer/dd/yy (amerikansk notasjon) : metadata
- Metadata bidrar til at data blir forstått riktig (skal gi mening)
- Metadata er nødvendig for at datamaskiner skal kunne tolke data

LITT om organisering av TEKSTIG informasjon

Et tekstlig dokument kan (blant annet) karakteriseres ved

- *Innhold*: Hva teksten uttrykker/formidler,
 - Eks: Roman, dikt, fagstoff, lovtekst, offentlig rundskriv, brosjyre,
- *Struktur*: Måten innholdet er organisert,
 - Eks. Bind, kapitler, avsnitt, nummerering, referanser,...
- *Form/utseende* (Layout, "design")
 - Skrifttyper/størrelser, farger/grafikk, sidestørrelse, spalter, bokser,

Disse er ikke uavhengige av hverandre

Litt om WWW og HTML

World Wide Web - hva er det ?

- Et informasjonssystem ?
- En bok ?
- Et (velorganisert) bibliotek ?
- Et leksikon ?

Svaret er kanskje både ja og nei:
Det kan framstå som alle disse formene -
men er egentlig ingen av delene


Organisering av informasjon (data) på WWW

Noen hovedbegreper:

- **Hjemmeside** (home page): Førstesiden (ofte kalt startsiden for et **nettsted**, (web-site))
 - Eks: <http://www.uio.no/>, <http://www.afin.uio.no/>
 - En hjemmeside identifiseres ved en **URL** (Unified resource locator)
- **Lenke**: peker til et annet dokument
- **Hypertext**: tekst som inneholder lenker til andre dokumenter (*URL'er)
- **Nettleser** (Browser) som henter og presenter filer på WWW ved hjelp av http og HTML.
 - Eks. Internet Explorer, Opera, Firefox,..

DRI 2010 -H09 90909 Arild Jansen , AFIN

Strukturen på ett nettsted



DRI 2010 -H09 90909 Arild Jansen , AFIN

Hvordan representeres dokumenter

- Dokumenter har blant annet
 - En **identifikasjon** (vanligvis 'navn', kap i en bok, forfatter/dato), På Internett ved **URL** /
 - **Utseende** - formatet eller layout, dvs. slik det framstår (presenteres) på skjerm eller papir. Her bruker vi **HTML** for å bestemme utseende på WWW.
 - **Strukturen** - hvordan et dokument er organisert i ulike deler , f eks. bok: Tittel, forfatter, innholdsliste, kapitler, sider,..
 - **Innholdet**, dvs. teksten vi er interessert i
 - Innholdet kan skrives ved tekstredegatingsprogram (Word, OpenOffice Writer, men det gir lite/ingen informasjon om hva innholdet betyr

Et dokument kan ha ulike typer fysisk **representasjon**, f eks. skriftlig, nedkopier på mikrofilm, digital på disk, disketter, Cd-rom, Det kan formateres på ulike måter
Det kan organiseres på ulike måter .

Men innholdet (betydningen, meningene) skal ikke endres

DRI 2010 -H09 90909 Arild Jansen , AFIN

Merking av fritekst : HTML

HTML: Hyper Text Markup Language -

Et standard "språk" for å beskrive layout (format) av et dokument i fritekstformat for presentasjon

HTML-kodene angir hvordan dokumentet skal presenteres:

Et HTML-dokument består av 2 deler (nivåer)

1.: Det vi ser på skjermen

2: Kodene i dokumentet (normalt vises de ikke)

HTML: "Markup -språk "

- Beskriver utseende (layout,format), ikke innhold
 - I HTML merkes "tagges" tekst for å angi format
 - (Stammer fra boktrykkeriene, eks å markere "ingressss", "avsnitt" i margen på en side)

Eks: HTML-sekvensen:

....Vanlig tekst utevet <I> kursiv </I>
 ny tekst

blir således :

Vanlig tekst **utevet** *kursiv* ...

ny tekst

- HTML består av et bestem sett av markeringer (Tag-typer)
- HTML-setninger kan leses av alle nettlesere (forutsatt at de bruker standard)
 - Word kan oversette fra .doc format til .html (men lager dårlig html-kode !!!)

Hva er HTML- fortsatt

Noen grunnleggende HTML-koder:

```
<HTML>
  <HEAD>
    <TITLE>Avdeling for forvaltningsinformatikk</TITLE>
  </HEAD>
  <BODY>
.....<A href="http://www.jus.uio.no/">JURIDISK FAKULTET</A>
  </body>
</HTML>
```

Hentet fra <http://www.afin.uio.no/>

Er HTML tilstrekkelig for å beskrive fritekst

- Layout? JA
- Struktur? Begrenset
- Innhold? Svært lite
- HTML er primært en markeringsnotasjon, som beskriver hvor et dokument skal se ut

DRI 2010 -H09 90909 Arild Jansen , AFIN


Kort om XML

- Extensible Markup Language (XML) er enkelt språk for å beskrive dataformater (struktur og innhold, og ikke layout-utseende).
 - XML kan brukes til å utveksle data mellom systemer
 - XML kan brukes til å lagring av semistrukturerte data, f eks. boktekster, web-sider, ...
 - XML har en strengere syntaks (grammatikk) enn HTML
- Se mer: <http://www.w3.org/XML/>
- Se eksempler på
http://www.brreg.no/samordning/grunndata/gr1b_basisdata_tamini.html

DRI 2010 -H09 90909 Arild Jansen , AFIN

XML - Extensible markup language

- XML kan beskrive struktur og innhold
- Eks. en beskrive struktur i en bok



DRI 2010 -H09 90909 Arild Jansen , AFIN

Eksempel på XML-kode, inkludert HTML-kode

```
<?XML versjon = "1.0" Encoding = "ISO-8859-1"?>
<bok>
  <description>
    <title>Fra Kjernen og ut, fra skallet og inn </title>
    <author>
      <first-name>Gerhard </first name>, <Last-name>Skagestein</last-name>
    </author>
  </description>
  <body>
    <Forord> I denne boka vil jeg...</forord>
    <chapter title = "Innledning">
      <p> I dette kapitlet ser vi på .....
      .....
    </chapter>
    Chapter title = "systemutviklingprosessen"
  </body>
</book>
```

(fra Skagestein, kap. 17 forenklet. Fargene er for å synliggjøre teksten)

DRI 2010 -H09 90909 Arild Jansen , AFIN

Eksempler på metadata på emnesidene

Eksempler

- <http://www.uio.no/studier/program/>
- <http://www.uio.no/studier/emner/jus/afin/DRI1001/h08/>
- <http://www.uio.no/studier/emnegrupper/>
- <http://www.uio.no/studier/emner/>

DRI 2010 -H09 90909 Arild Jansen , AFIN

Beskrivelse av innholdet i tekst bruk av ontologier

- Ontologi : an **ontology** is a formal representation of a set of concepts within a **domain** and the relationships between those concepts. (http://en.wikipedia.org/wiki/Ontology_%28computer_science%29)
 - Eks på ontologier et Linnee's plantelære, begreper innen ulike deler av matematikken, osv.
- Det blir nå definert ontologier for å kunne beskrive innholdet i tekster på ulike fagområder (domener), f eks. for å beskriver lover, eller dokumenter i forvaltningen ved standard begreper
 - Eks. på XML-baserte ontologier er LegalXML, [Government XML](#)
- XML-baserte ontologier inngår som en sentral del av den semantiske veven

Noen forskjeller mellom HTML og XML

- HTML beskriver bare utseende - ikke hva dataene betyr
- HTML har en løs syntaks (*feil oppdages ikke lett*)
- HTML har et begrenset sett av fast definerte *markeringer* og tilhørende attributter (*egenskaper*)
- XML kan beskrive både struktur og utseende
- XML har en strengere syntaks
 - Dette gjør at feil kan oppdages før et program brukes
- XML tillater egendefinerte markeringer og attributt-navn

DRI 2010 -H09 90909 Arild Jansen , AFIN

Meget kort om emnekart

- Emnekart ([eng.](#) *Topic Maps*) er en [ISO](#)-standard for representasjon og utveksling av strukturert og semistrukturert informasjon.
- Et emnekart består av et sett med *emner* av forskjellige typer. Disse emnene er knyttet sammen i en grafstruktur gjennom *assosiasjoner*. Et emne representerer et *tema*
- Eksempler på bruk av emnekart i Norge:
 - GREP, Se <http://www.utdanningsdirektoratet.no/grep>
 - Regjeringen.no, se <http://www.regjeringen.no/nb.html?id=4>

Bruk av emnekart vil bli gjennomgått på forelesningen 23.9
