

# Markeringsspråk og XML

## Nettsider og XHTML

```
<?xml version = "1.0" encoding="ISO-8859-1"?>

<eventyr>

Det var en gang...

...

og snipp, snapp, snute, så var det eventyret ute.

</eventyr>
```

Læreboka kapittel 3 og 4

5. september 2007

# **XML og XHTML**

- XML = EXtensible Markup Language**
  - Laget for å beskrive informasjon.
  - Brukes for
    - » Lagring av semistrukturerte data.
    - » Overføring av data mellom systemer.
- XHTML = EXtensible HyperText Markup Language**
  - Laget for å vise frem informasjon.
  - Brukes for
    - » Markering av tekster som skal vises frem av en nettleser.
- Standardisert av World Wide Web Consortium – se**  
**<http://www.w3.org/>**

# Markering av tekst

## □ Spesifikk markering (eksempel fra WordStar)

.PL 66

page length 66 linjer

.MT 6

margin top = 6 linjer

.MB 9

margin bottom = 9 linjer

**^B Innhold INF1040^B**

switch bold on and off

I **INF1040** skal vi blant annet lære ...

## □ Generalisert markering (eksempel fra XHTML)

<h1>Innhold INF1040</h1>

<p>I <strong>INF1040</strong> skal vi blant annet lære...</p>

## □ Generisk markering (eksempel fra XML)

<chapter>

<chapter name>Innhold INF1040</chapter name>

<paragraph>I <span>INF1040</span> skal vi blant annet lære...

</paragraph>

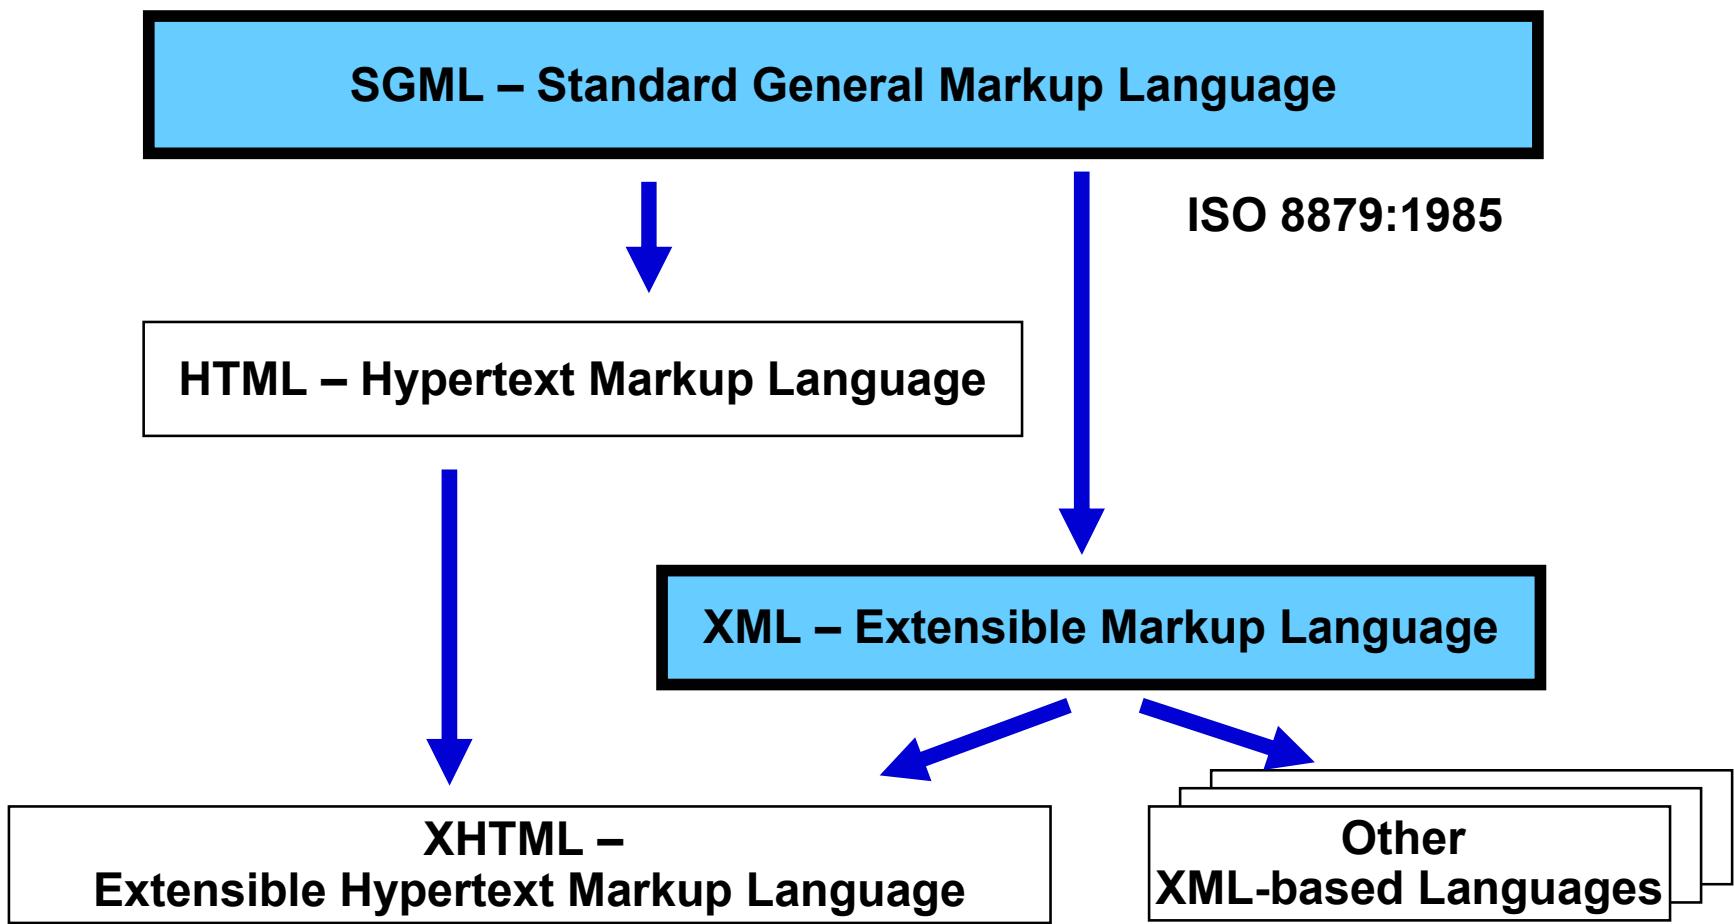
...

</chapter>

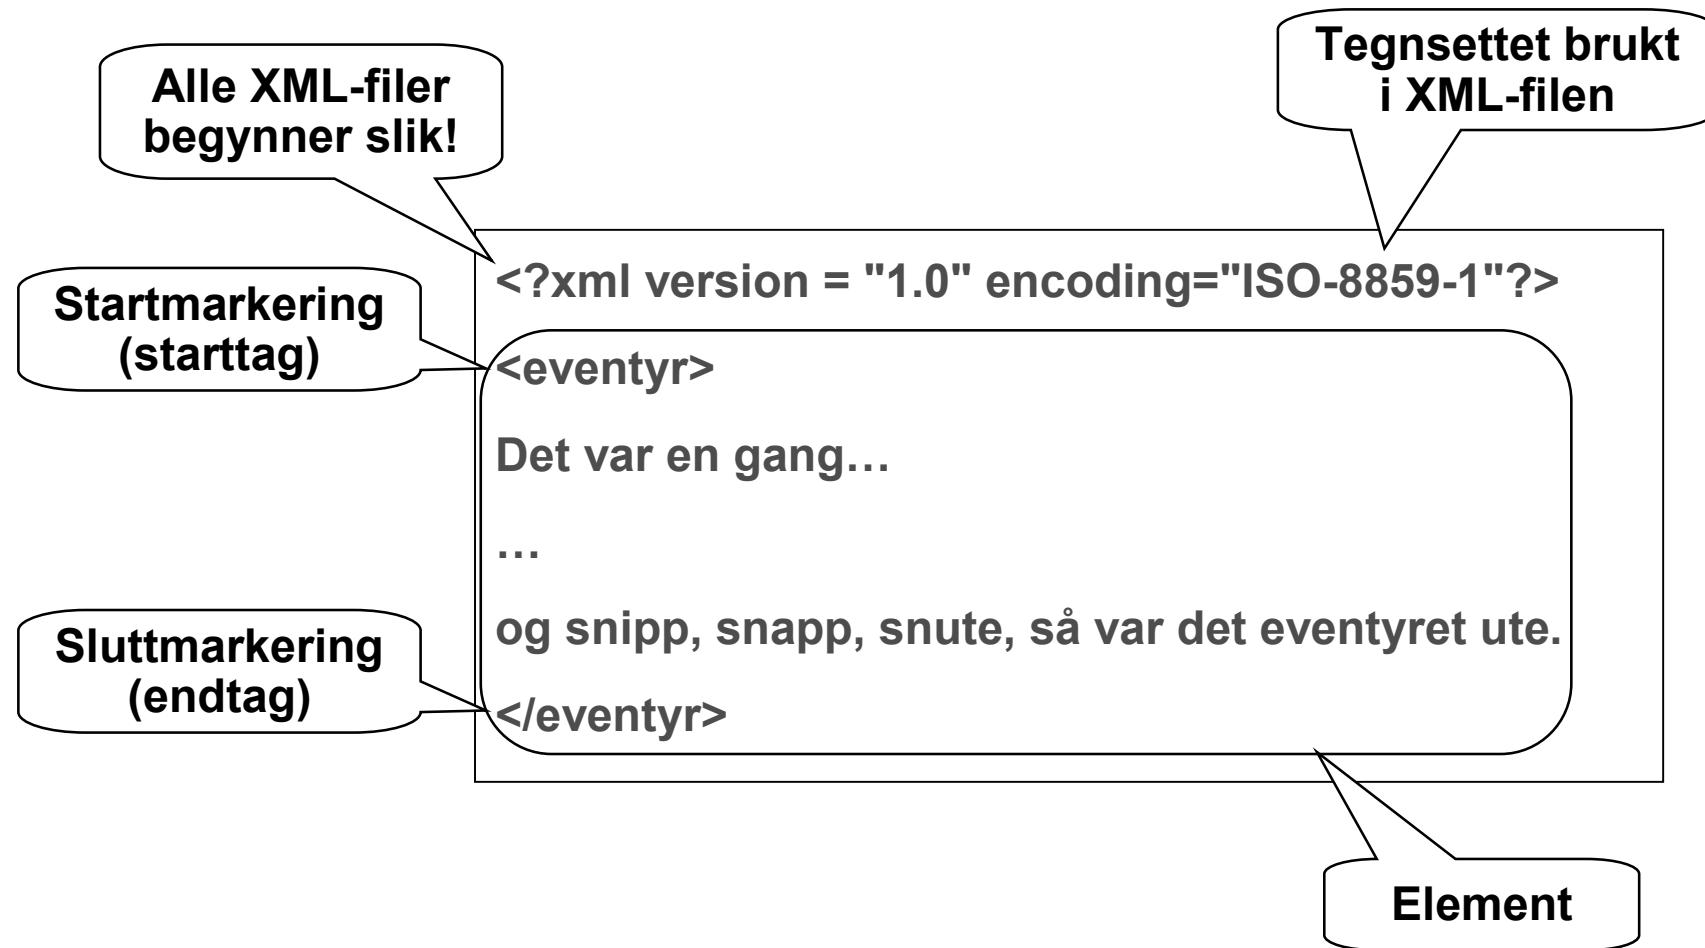
# Direkte redigering av markert tekst

- Trinn 1: Generalisert eller generisk markering**  
**Hver enkelt del av teksten deklarerdes til å være av en bestemt type (f.eks. overskrift, brødtekst, sitat, liste...)**
- Trinn 2: Formatering**  
**Hver av teksttypene tilordnes en kombinasjon av formater (ofte kalt en stil).**
- Prinsipp: Skill mellom innhold (hva er teksten) og visualisering (hvordan vise frem teksten).**

# SGML-familien



# Et meget enkelt XML-eksempel



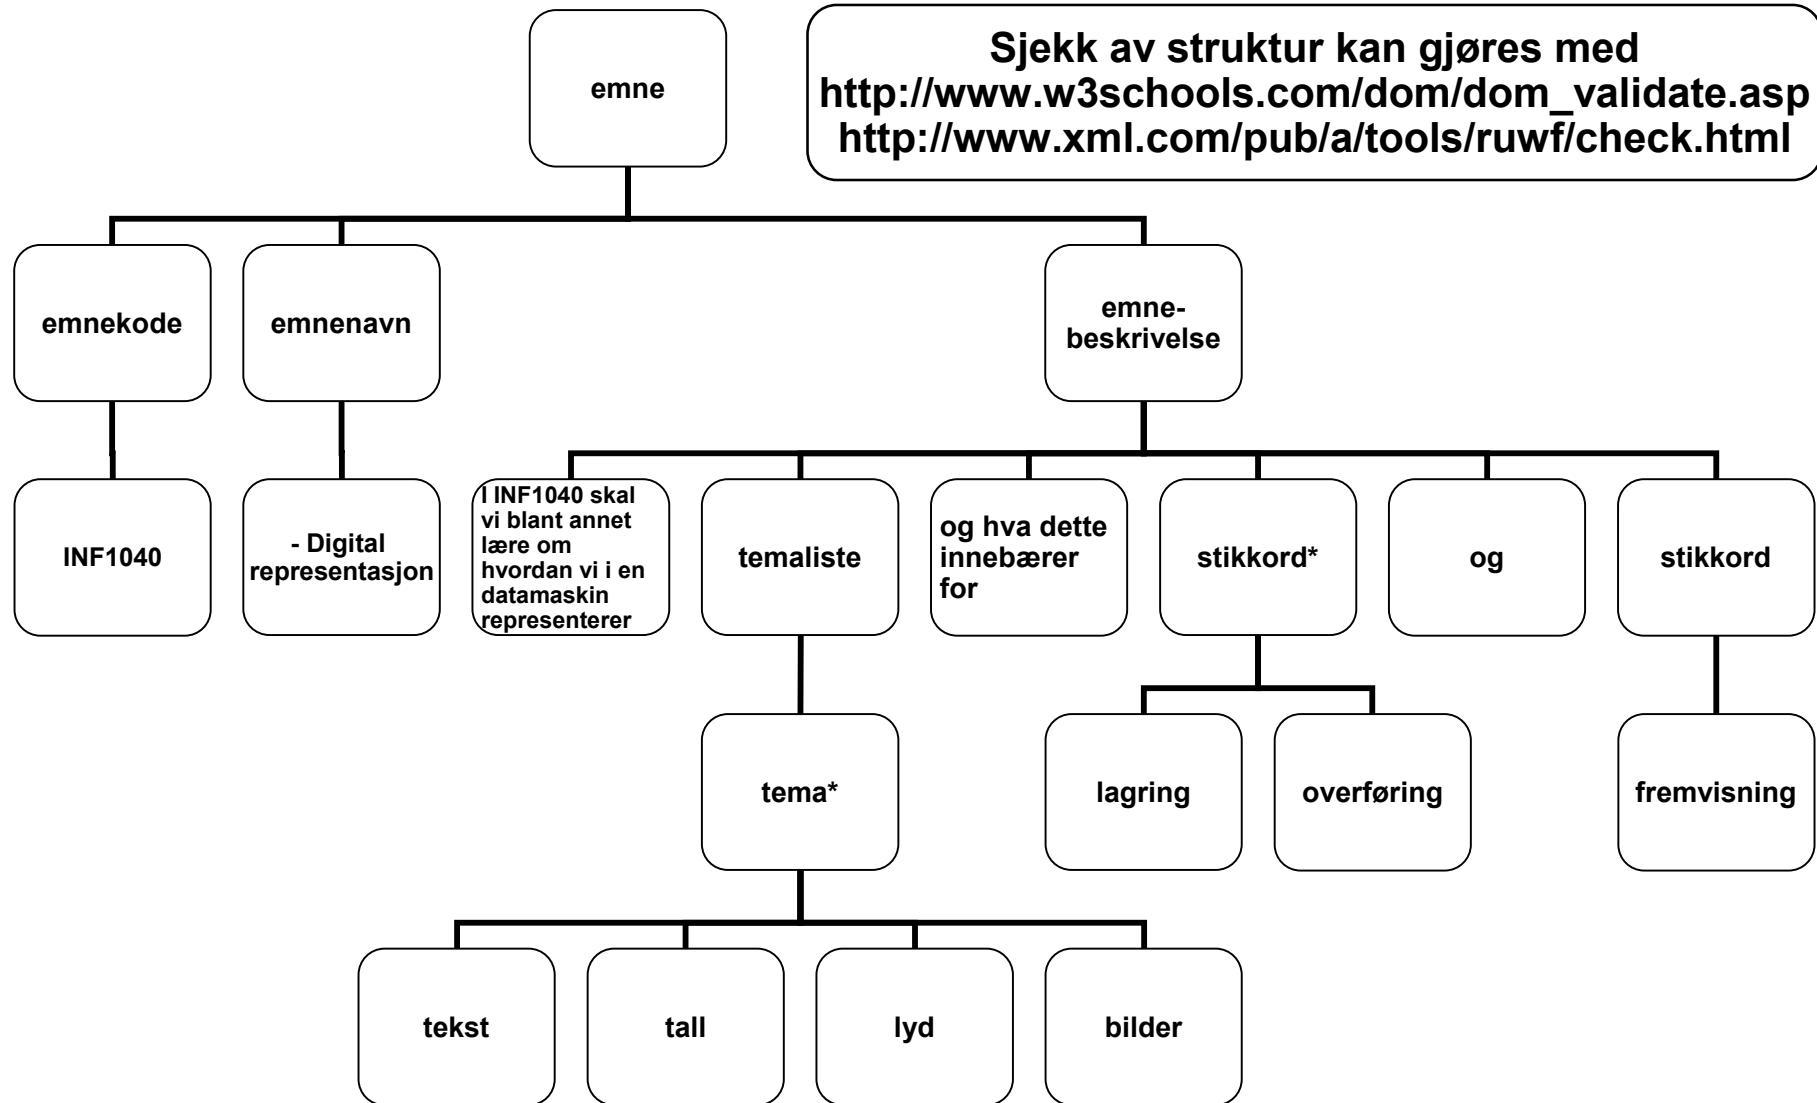
# Et litt mer avansert XML-eksempel

```
<?xml version = "1.0" encoding="ISO-8859-1"?>
<emne id="ifi12345">
<emnekode>INF1040</emnekode>
<emnenavn>Digital representasjon</emnenavn>
<emnebeskrivelse>I INF1040 skal vi blant annet lære om hvordan vi i en
datamaskin representerer
<temaliste>
  <tema>tekst</tema>
  <tema>tall</tema>
  <tema>lyd</tema>
  <tema>bilder</tema>
</temaliste>
og hva dette innebærer for
  <stikkord>lagring</stikkord>,
  <stikkord>overføring</stikkord> og
  <stikkord>fremvisning</stikkord>.
</emnebeskrivelse>
</emne>
```

*Vi snakker gjerne om et "XML-dokument", selv om det ikke er meningen å skrive det ut på papir.*

*Terminologien understreker imidlertid at XML er et tekstbasert format.*

# Elementene danner en hierarkisk struktur



# Oppbygningen av et element

- Et element må ha både en start- og en slutt-markering  
`<markering>elementinnhold</markering>`
- Elementer kan ha attributter i startmarkeringen: `attributt="verdi"`
- Tomme elementer kan ha en kombinert kombinert start- og sluttmarkering `<markering/>`
- Regler for elementnavn
  - Kan inneholde bokstaver, tall og andre tegn.  
Ikke-engelske bokstaver er tillatt,  
men det er ikke sikkert all programvare forstår dem
  - Kan ikke inneholde mellomrom (space)
  - Kan ikke starte med tall, skilletegn eller xml, XML, Xml (men med \_)
  - Unngå tegnene – . : De kan lett misforstås

# Spesielle tegn

- Tegnene < > & har en spesiell betydning i XML  
(de brukes som "escape"-tegn)
- Hvis slike tegn inngår i teksten, må de kodes på en spesiell måte:  
`&tegnavn;` eller `&#kodepunkt;`
- altså:

<	<code>&amp;lt;</code>	<code>&amp;#x3C;</code>
>	<code>&amp;gt;</code>	<code>&amp;#x3E;</code>
&	<code>&amp;amp;</code>	<code>&amp;#x26;</code>
- For konvertering fra Unicode-tegn til heksadesimal, bruk for eksempel <http://pioneer.stereo.lu/converter.html>

*x betyr at kodepunktet er angitt i heksadesimal!*

# To anvendelser av XML

- **Som et “lingua franca” mellom systemer**
  - Endelig en “standard” !
  - Emneorienterte markeringer må defineres  
(begge systemer må ha samme oppfatning av <eventyr>)
  - Er tekstlig format alltid hensiktsmessig?
  - Stor datamessig “overhead”  
Men: Store muligheter for komprimering
- **Lagring av XML-dokumenter i en database**
  - “Native” XML-database
  - Trenger vi enda en type database?

# Eksempel på en Dokumenttypedefinisjon - DTD

Dokumenttypedefinisjon på filen emne.dtd:

```
<!ELEMENT emne (emnkode, emnenavn, emnebeskrivelse)>
  <!ELEMENT emnkode (#PCDATA)>
  <!ELEMENT emnenavn (#PCDATA)>
  <!ELEMENT emnebeskrivelse (#PCDATA|temaliste|stikkord)*>
    <!ELEMENT temaliste (tema*)>
      <!ELEMENT tema (#PCDATA)>
    <!ELEMENT stikkord (#PCDATA)>
```

På filen emne.xml

```
<?xml version = "1.0" encoding="ISO-8859-1"?>
<!DOCTYPE emne SYSTEM "emne.dtd">
<emne>
  <emnkode>INF1040</emnkode>
  ...
  ...
```

Dokumenttypedeklarasjon

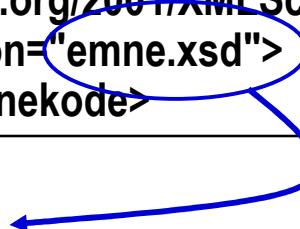
Parced Character  
Data, dvs vanlig tekst

# Et XML-skjema

På filen emne.xsd:

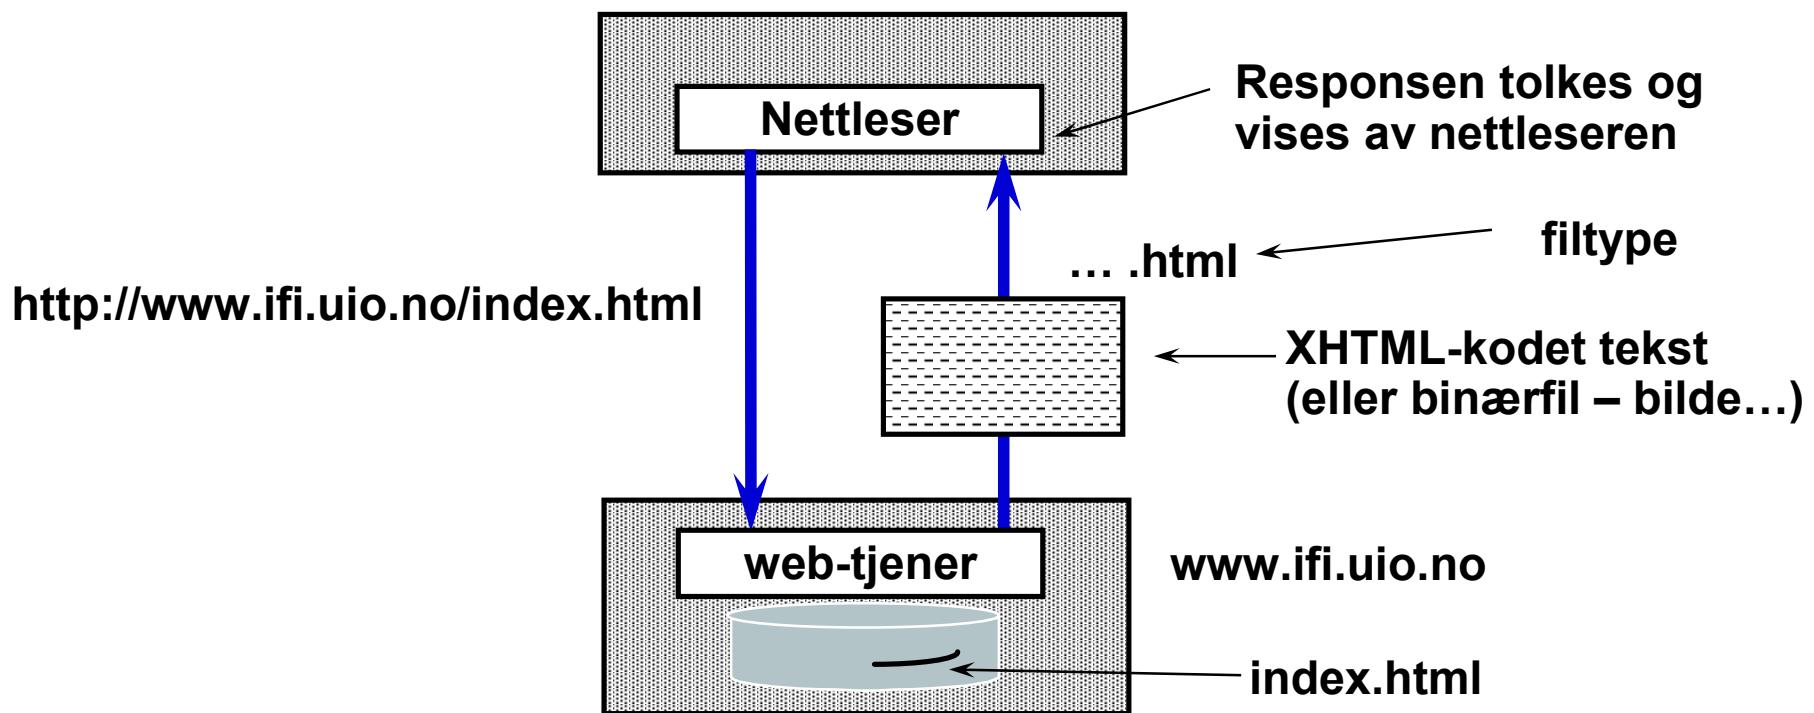
```
<?xml version="1.0" encoding="ISO-8859-1"?>
<xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema">
    <xs:complexType>
        <xs:sequence>
            <xs:element name = "emnekode" type="xs:string"/>
            <xs:element name = "emnenavn" type="xs:string"/>
            <xs:element name = "emnebeskrivelse">
                <xs:complexType mixed="true">
                    <xs:element name = "tema" type="xs:string"
minoccurs="2" maxoccurs="10"/>
                    <xs:element name = "stikkord" type="xs:string"
minoccurs="0" maxoccurs="unbounded"/>
                </xs:complexType>
            </xs:sequence>
        </xs:complexType>
    </xs:schema>
```

```
<?xml version = "1.0" encoding="ISO-8859-1"?>
xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
<emne xsi:schemaLocation="emne.xsd">
<emnekode>INF1040</emnekode>
```



# XHTML – Extensible Hypertext Markup Language

- XML med en spesiell DTD egnet for utforming av nettsider  
se <http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd>
- Erstatning for HTML – Hypertext Markup Language
- Viktig bestanddel av Hypertext Transfer Protocol – HTTP



# Tre varianter av XHTML

For XHTML kan vi velge mellom tre ulike DTDer

**Transitional**

Litt romslig DTD som bl.a. tillater elementer og attributter som har med visuell presentasjon å gjøre.

Egnet for XHTML som er oppussede versjoner av tradisjonell HTML

**Frameset**

DTD som tillater bruk av rammer ("frames").

Omdiskutert teknologi.

**Strict**

DTD som utelukker elementer og attributter som har med visuell presentasjon å gjøre – dette skal uttrykkes i stiler og stilark

***Vi skal bruke strict!***

# Hva INF1040 ikke dekker

- Dynamiske nettsider (INF1050)**  
Nettsider som bygges opp "on the fly" på web-tjeneren,  
ofte på grunnlag av data som hentes fra en database
- Forms (INF1050)**  
Formularer som brukeren av nettstedet kan fylle ut
- Image-maps**  
Klikkbare bilder
- Klient-programmering**  
Bruk av skriptspråk for å skape liv i nettsiden
- Java-Applets og ActiveX-controls**  
Små programmer som lastes ned fra web-tjeneren og som utføres  
på klienten
- Sikkerhetsaspekter**

# Den minimale XHTML nettside

```
<?xml version="1.0" encoding="UTF-8"?>  
<!DOCTYPE html  
    PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN"  
    "http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">  
  
<html xmlns = "http://www.w3.org/1999/xhtml">  
    <head>  
        <title> En minimal nettside </title>  
    </head>  
    <body>  
        <p>Hallo, verden!</p>  
    </body>  
</html>
```

Angivelse av  
DTD

Angivelse av  
navnerom

# Publisering av nettsiden (på Ifi)

- Legg opp en mappe med navn **www\_docs** på brukerområdet ditt (hvis den ikke er der fra før), og gi den tilgangstillatelse 755
  - > **chmod a+rx www\_docs**
- Legg XHTML-teksten du vil publisere i mappen **www\_docs**, sørг for at filtypen er html eller htm, og gi filen tilgangstillatelse 644
  - > **chmod a+r fil.html**
- Nå er nettsiden tilgjengelig under URLen  
**http://folk.uio.no/~brukernavn/filnavn.html**

*I det øyeblikk du har satt tilgangstillatelsene, er nettsiden offentlig tilgjengelig ved hjelp av nettlesere over hele Internett.*

**Tenk over hva du publiserer!**