Uppmärkningsspråk

TDP007 Konstruktion av datorspråk
Föreläsning 4

LINKÖPINGS UNIVERSITET

CC BY SA

Pontus Haglund (anpassat från Peter Dalenius)
Institutionen för datavetenskap
2022-01-24

Från förra gången

- XML-dokument specificeras med t.ex. en DTD
- Två olika sätt att parsa XML-dokument:
  - *Strömparsning läser in dokumentet, i princip ett tecken i taget, och skickar signaler när något hittas (starttagg, sluttagg, etc)*
  - *Trädparsning*

2. Trädparsning

Vid trädparsning läses hela XML-filen in på en gång och parsern returnerar ett objekt som motsvarar hela innehållet, enligt DOM (Document Object Model).

```
<?xml version="1.0"?>
<note>
  <to>Ola</to>
  <from>Peter</from>
  <heading>Öl på
fredag?</heading>
  ...
</note>
```

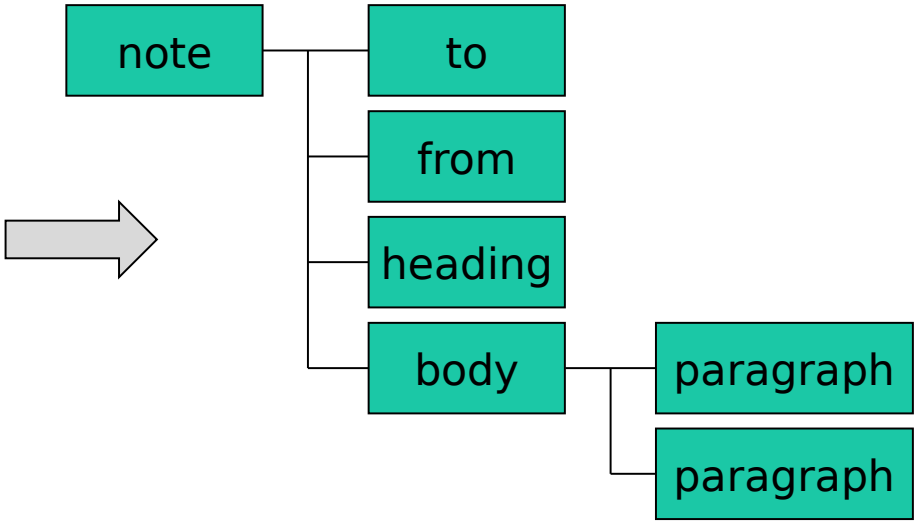

Officiell specifikation: www.w3.org/DOM

Exempel på användning av DOM

```
>> require 'rexml/document'
=> true
>> src = File.open "note2.xml"
=> #<File:note2.xml>
>> doc = REXML::Document.new src
=> <UNDEFINED> ... </>
```

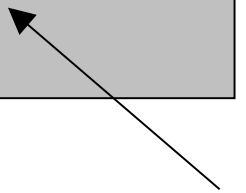

Detta anrop parsar hela XML-filen och returnerat ett DOM-objekt. Vad finns i detta objekt och hur kommer man åt det?

DOM-struktur för vårt XML-exempel

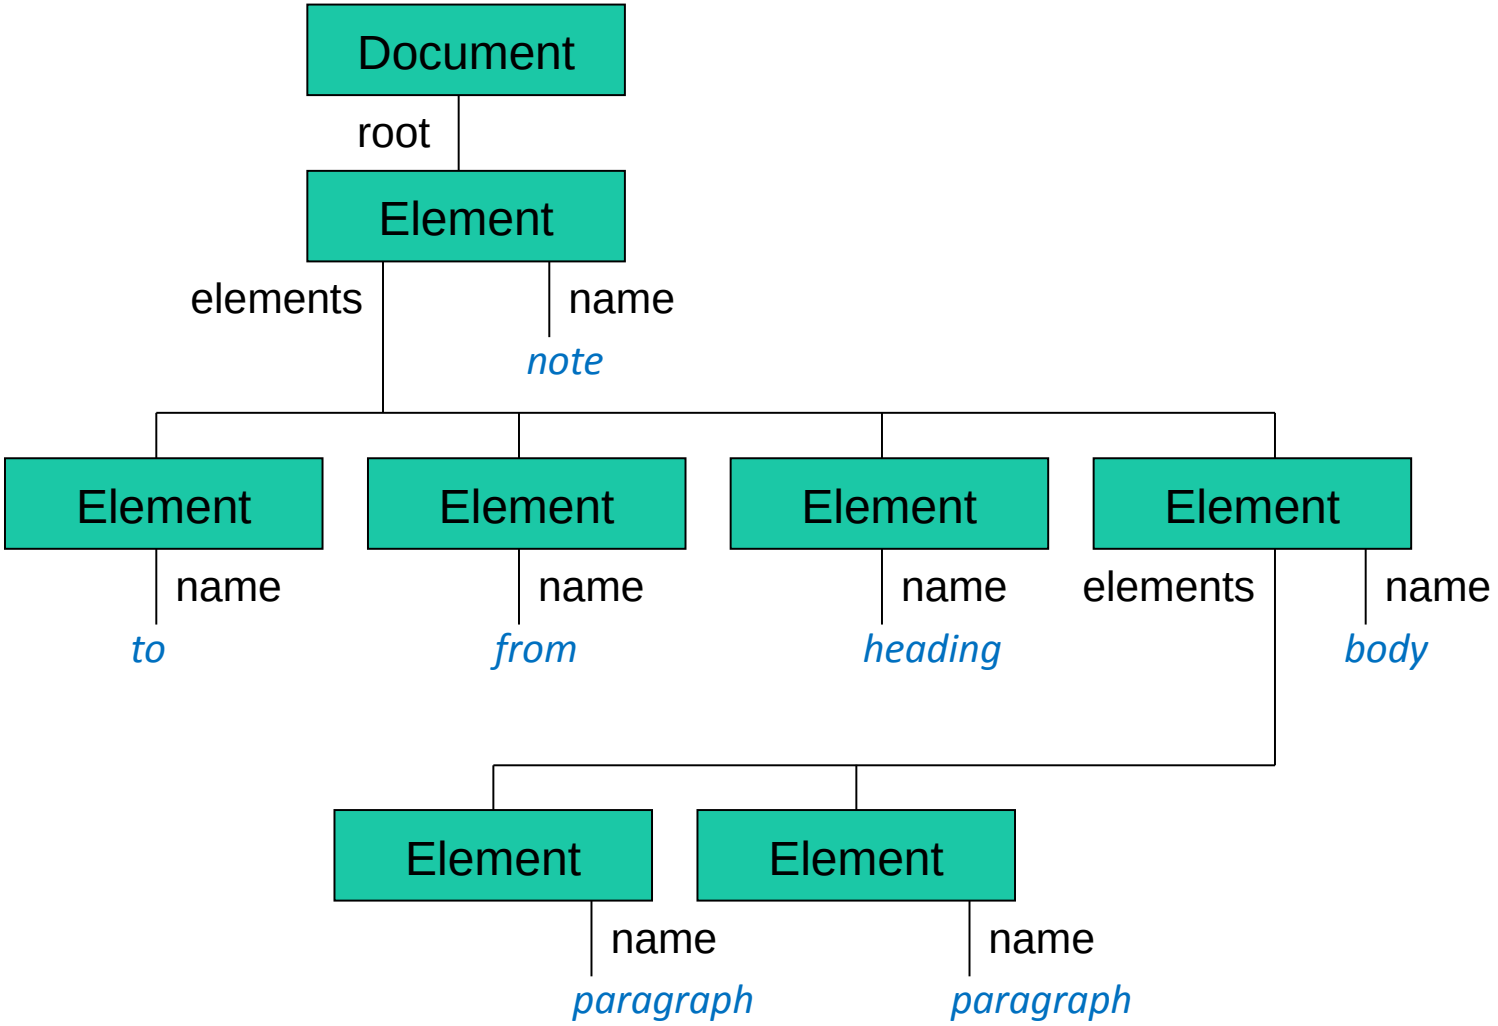

Exempel på metoder för DOM

```
>> doc = REXML::Document.new src
=> <UNDEFINED> ... </>
>> doc.class
=> REXML::Document
>> r = doc.root
=> <note> ... </>
>> r.class
=> REXML::Element
>> r.name
=> "note”
>> r.elements[1].name
=> "to”
>> r.elements[4].elements[2].text
=> "Förresten, stället heter De Klomp."
```

Dokumentet är ett objekt av klassen **Document**. Det har ett attribut **root** som representerar rotelementet.

Varje element har en ”array” **elements** som innehåller ”barnen”. Observera att den har basen 1, inte 0.

Attributet **name** innehåller elementets namn.

Övning

- Ladda in filen **note2.xml** och plocka ut namnen på sändare och mottagare ur DOM-objektet.
- Ladda in följande funktion från **print_tree.rb**, kör den på det inlästa XML-dokumentet och förklara vad som händer.

```
def print_tree(elem, indent=0)
  elem.elements.each do |subelem|
    puts " "*2*indent + subelem.name
    print_tree(subelem, indent+1)
  end
end
```

XPath

- Att plocka fram elementen ur dokument-objektet gör att man måste hårdkoda dokumentets specifikation i programmet. Det är inte så flexibelt att peka ut delar av dokumentet med uttryck som **r.elements[4].elements[2].text.**
- Ett lite enklare sätt är att använda XPath.
- XPath (XML Path Language) är ett språk för att välja ut delar av ett XML-dokument. Man kan tänka på det som ett sätt att formulera sökvägar till delar av dokumentet.
- Flera av funktionerna i REXML-paketet stödjer XPath-uttryck.
- XPath 1.0 är från 1999, XPath 2.0 är från 2007 och XPath 3.0 är från 2014.

Exempel på XPath-uttryck

Alla *paragraph*-noder inuti en *body*, inuti en *note* som är roten i dokumentet.

```
>> doc.elements.each("/note/body/paragraph") { |n| puts n.text }
Det har öppnat ett nytt holländskt ställe
på S:t Larsgatan. De lär ha en massa sorters holländsk
öl på fat. Vad sägs om att vi testar det på fredag kväll?
Förresten, stället heter De Klomp.
=> …
>> doc.elements.each("//body/*") { |n| puts n.text }
Samma resultat som ovan…
```

Alla noder, vilka som helst (*), som ligger inuti en body som ligger någonstans under roten, oavsett nivå.

Konstruktion av XPath-uttryck

- Alla XPath-uttryck har en **kontext** som tjänar som utgångspunkt (en nod i dokumentet).
- Från utgångspunkten går man med hjälp av tre saker (alla behöver inte vara med):
  - *en **riktning**, t.ex. barn eller förälder*
  - *ett **nodtest**, t.ex. att man söker noder med ett visst namn*
  - *ett **predikat** som talar om att noderna ska ha ytterligare egenskaper*
- Läs på om XPath och experimentera på egen hand! Det finns gott om bra introduktioner på nätet.

Fler exempel på XPath-uttryck

/note/from	Väljer noden *from* som finns under noden *note* som finns direkt under dokumentets rot.
//from	Väljer noden *from* som finns någonstans under dokumentets rot.
paragraph[2]	Väljer den andra *paragraph-noden* som finns under den aktuella noden.
..	Väljer den aktuella nodens föräldranod.
@version	Väljer attributet version i den aktuella noden.
para[@color="blue"]	Väljer den första *para-noden* under den akteulla noden som har attributet *color* med värdet *blue*.

Övning

- Kopiera filen **animals.xml** och tillhörande DTD i filen **key.dtd**. Filen innehåller en bestämningsnyckel för djur.
- Skriv ett kort program som kan använda bestämningsnyckeln och ställa frågor till användaren.
- Tips: Leta upp API-dokumentationen för REXML-paketet på nätet!

  ruby-doc.org under *Standard Library API* eller via

  https://ruby.github.io/rexml/

```
<?xml version="1.0"?>
<!DOCTYPE key SYSTEM "key.dtd">

<key header="Animals">

<node id="start" header="Classification of animals">
<alt dest="bird">Has wings and flies</alt>
<alt dest="fish">Lives in the water</alt>
<alt dest="land">Mostly walks on the ground</alt>
</node>

<node id="bird" header="Birds">
<alt dest="parus_major">. . .</alt>
<alt dest="cyanistes_caeruleus">. . .</alt>
</node>

. . .

</key>
```

Microformat

- Microformats är en uppsättning små fria standarder för att representera vissa specifika typer av information.

Ett typiskt exempel är en överenskommelse om hur man kan bädda in kontaktinformation i en webbsida.

```
<span class=”vcard”><span class=”fn”>Kalle Kula</span></span>
```

- Mer information finns på **www.microformats.org**

Sammanfattning

- Tre sätt att bearbeta ett XML-dokument:
  - *Implementera egen SAX-lyssnare*
  - *Bygga DOM och använda metoder för element*
  - *Bygga DOM och använda XPath*
- Förkortningar vi har pratat om:
  - *API, DOM, DTD, HTML, SAX, SGML, XHTML, XML, XPath*

www.liu.se

LINKÖPINGS UNIVERSITET