# XPath

## XML, un langage d'arbres

Master Recherche SIA - Master Pro ILI - IG2I

Année 2011-12

# La représentation arborescente d'un document XML

- un document XML est représenté par un arbre
- qui comprend les éléments, les attributs, les zones de texte
- mais aussi les commentaires, les instructions de traitement, ...
- bonne compréhension : permet de se déplacer dans les arbres ! sous-tend :
  - l'API DOM
  - XPath

# Les noeuds d'un arbre

Il y a 7 types de noeuds différents.

**Les noeuds internes** :

- racine
  - se situe au-dessus de l'élément racine du document (`recette`, `message`, `html`...)
  - contient ce qui se trouve au-dessus de l'élément racine
    - les instructions de traitement,
    - les commentaires,
    - etc...
    - sauf la déclaration de document
  - sous la racine on peut trouver tous les types de noeuds
- élément :
  - peut contenir toutes les sortes d'autres éléments excepté le noeud racine
  - c'est une feuille s'il n'a ni attribut ni contenu

# Les noeuds d'un arbre

## Les feuilles de l'arbre

- attribut :
  - c'est un noeud en-dessous de l'élément qu'il qualifie
  - ce n'est pas un *fils* de l'élément qu'il qualifie
- texte :
  - la donnée de base d'un document XML !
  - toujours enfant d'un noeud élément (pas forcément fils unique)
  - c'est une chaîne de caractères contigus sans noeuds intermédiaires

# Les noeuds d'un arbre

## Les feuilles de l'arbre

- instruction de traitement

```
<?php
  echo "bonjour!";
?>
```

- commentaire

```
<!--
  ceci est un comentaire
-->
```

- espace de noms :
  - a une signification particulière et une influence sur le sous-arbre qu'il domine
    - n'est pas un attribut
  - n'est pas un noeud à part entière
  - mais n'est pas *fils* de l'élément qu'il qualifie

# La représentation arborescente

Cette représentation arborescente n'est pas isomorphe au document texte original :

- le prologue du document (déclaration XML + déclaration de type de document)
- les sections `CDATA`
- les appels d'entités
- le contenu de la DTD

ne sont pas conservés.

# XPath

XPath : langage de localisation et de sélection d'ensembles de noeuds dans un document XML.

Une expression Xpath retourne

- soit un ensemble de noeuds
- soit un booléen
- soit un nombre
- soit une chaîne de caractères

La dernière recommandation de XPath date du 23 Janvier 2007 et il s'agit de la version 2.0.

# Se déplacer dans les arbres

Tout d'abord, localiser des noeuds :

- on retrouve des éléments qu'on avait déjà vus avec les sélecteurs dans les CSS (actuellement CSS2).
- avec XPath, on peut aller plus loin (CSS3 pourrait implémenter complètement XPath).

Mais . . .

# Contexte de recherche

Une expression XPath est calculée à partir d'un contexte.

Un contexte est déterminé par :

- un noeud (le noeud-contexte) ;
- un couple d'entiers positifs : l'indice du noeud-contexte dans l'ensemble dont il est issu, la taille de cet ensemble ;
- des variables et leur valeur ;
- une librairie de fonctions ;
- un ensemble d'espaces de noms.

# Chemin de localisation

Un chemin de localisation est

- soit un chemin absolu : depuis la racine, il commence par /
- soit un chemin relatif : il commence depuis le noeud-contexte.

Un chemin est ensuite constitué d'étapes qui permettent d'avancer dans la localisation.

Syntaxe d'un chemin : étape/étape/étape/...

# Chemin de localisation

Une étape a trois composantes :

- un axe : il détermine la direction à prendre
- un test de noeud : il précise le type de noeud à sélectionner
- des prédicats optionnels qui permettent d'affiner la sélection

Syntaxe :

```
axe::test-de-noeud[prédicat]*
```

Chaque élément peut-être omis.

# Axes

Les axes possibles sont :

- parent : le parent du noeud contextuel
- ancestor : tous les noeuds placés au-dessus du noeud contextuel
- ancestor-or-self : idem avec le noeud contextuel
- child : les enfants . . .(rappel :sauf les attributs et les espaces de noms)

# Axes

- descendant : tous les noeuds en-dessous du noeud contextuel
- descendant-or-self : idem avec le noeud contextuel
- self : le noeud lui-même
- attribute : les attributs du noeud contextuel
- namespace : tous les noeuds d'espaces de noms actifs pour le noeud contextuel

# Exemple

```
<?xml version="1.0" encoding="iso-8859-1"?>
<message priorité="importante">
  <!-- le destinataire --><dest>M. Dupont</dest>
  <!-- l'expéditeur --><exp>Melle. Dumoulin</exp>
  <!-- le sujet --><obj>alimentation du chat</obj>
  <corps>
    <para>Conformément à vos instructions, je donne
<emphase>trois</emphase> rations de croquettes
par jour à <nomduchat />.</para>
    <para><nomduchat /> a cependant
pris <emphase>deux</emphase> kilos pendant
les vacances.</para>
  </corps>
  <!-- pour finir --><form-pol style="simple"/>
  <!-- signature --><sign>Melle. Dumoulin</sign>
                  e>
```

# Axes

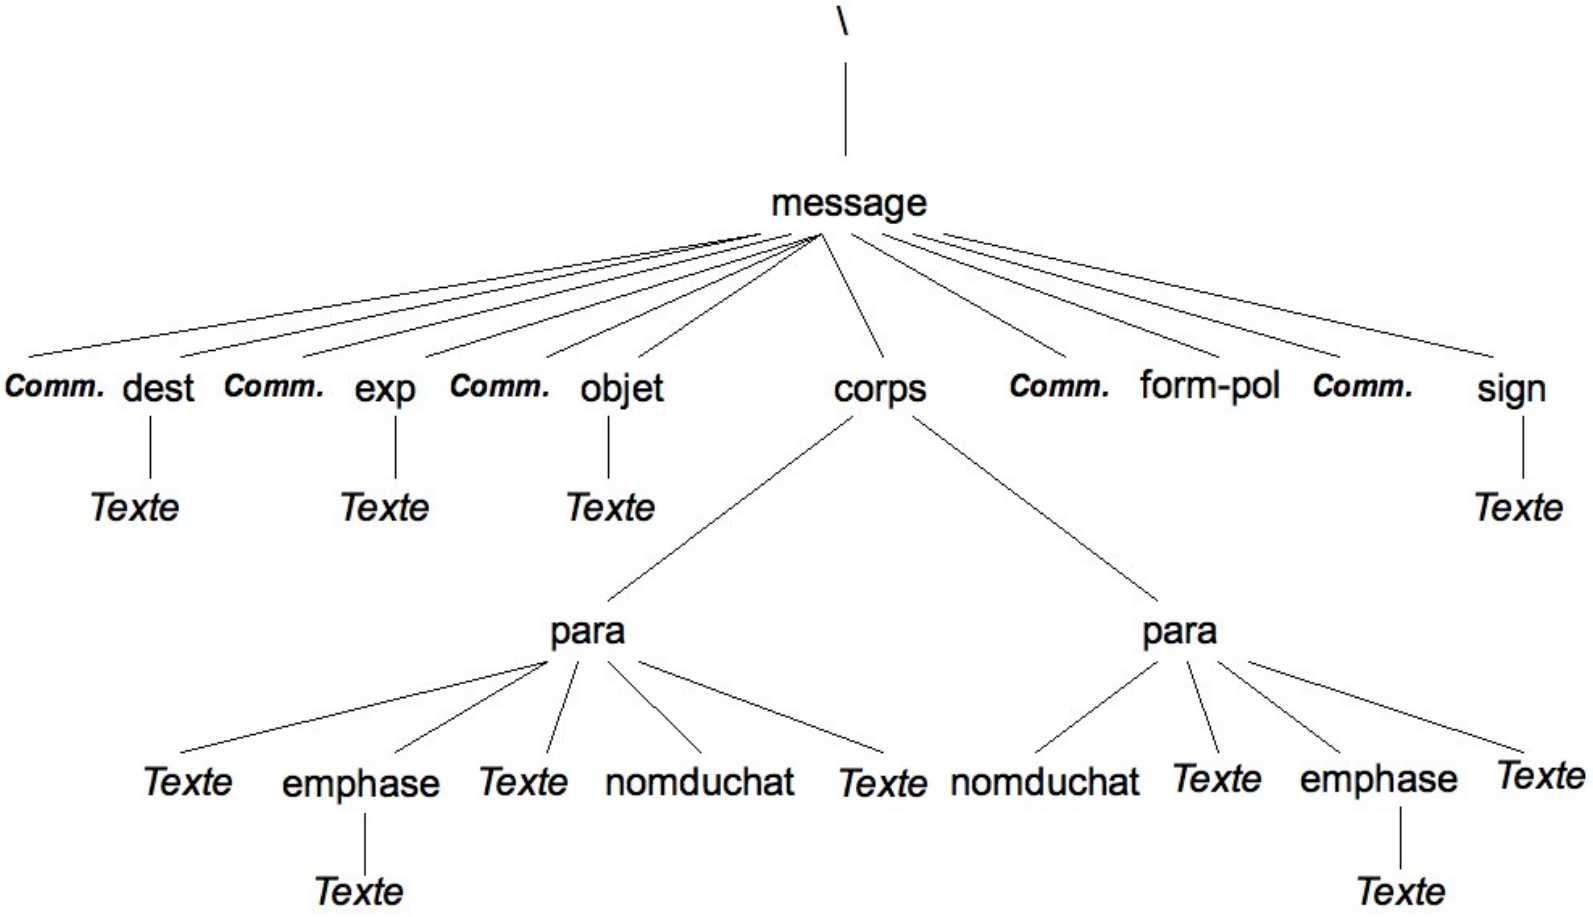
\
message
Comm.
dest
Comm.
exp
Comm.
objet
corps
Comm.
form-pol
Comm.
sign
Texte
Texte
Texte
Texte
para
para
Texte
emphase
Texte
nomduchat
Texte
nomduchat
Texte
emphase
Texte
Texte
Texte

# Axes

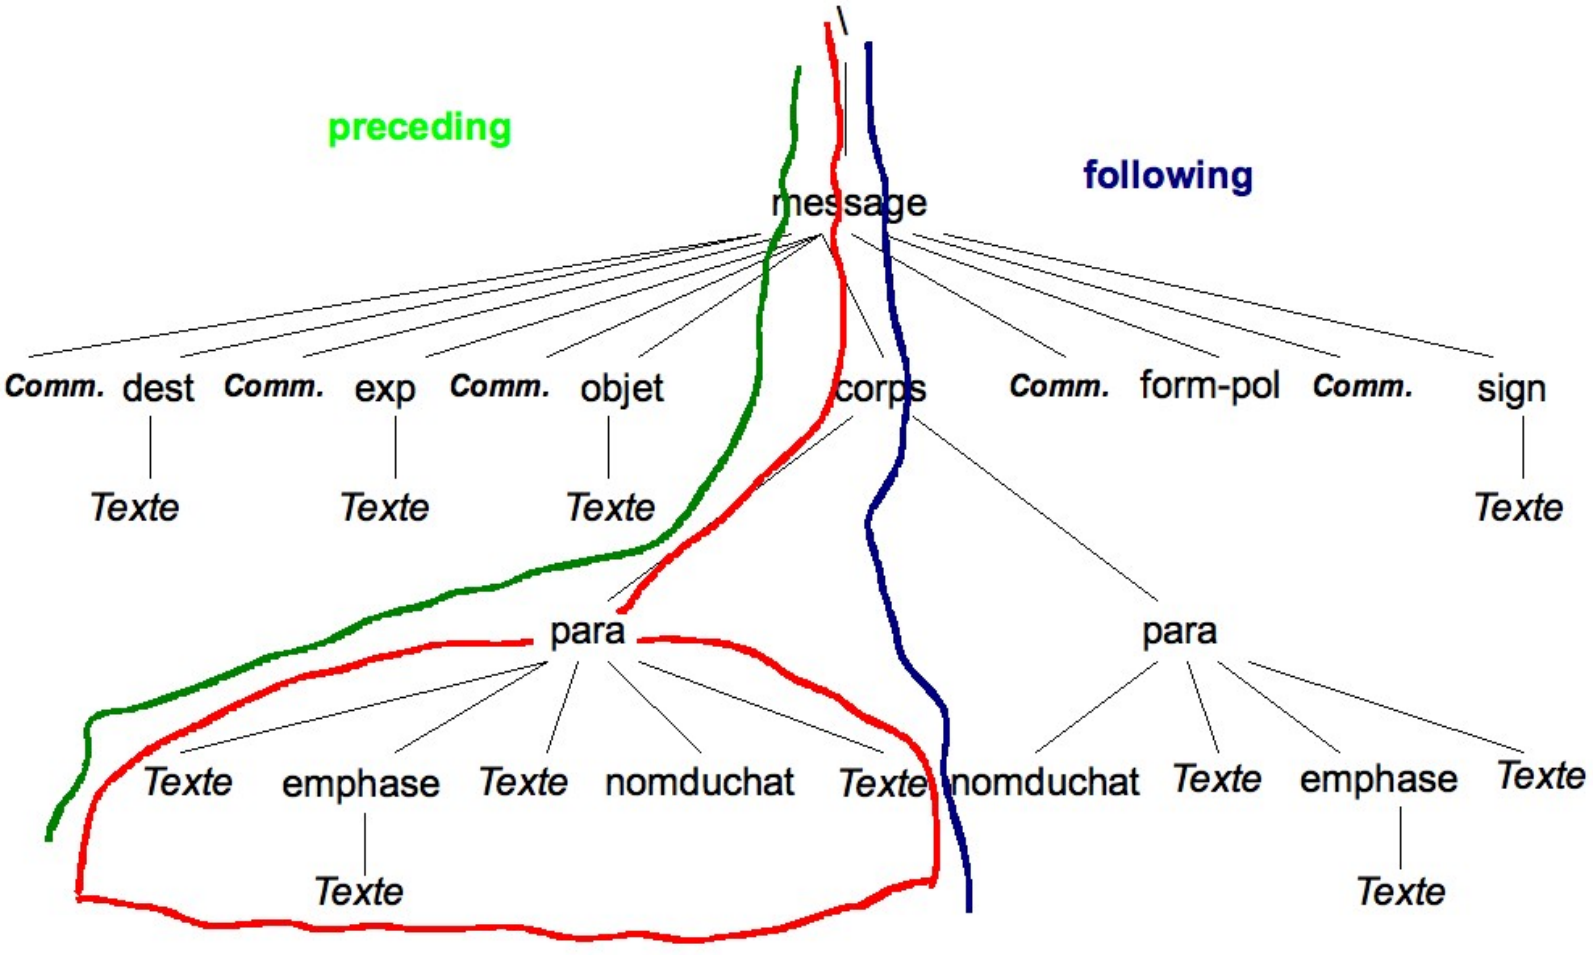
preceding
following
message
Comm.
dest
Comm.
exp
Comm.
objet
corps
Comm.
form-pol
Comm.
sign
Texte
Texte
Texte
Texte
para
para
Texte
emphase
Texte
nomduchat
Texte
nomduchat
Texte
emphase
Texte
Texte
Texte

# Axes

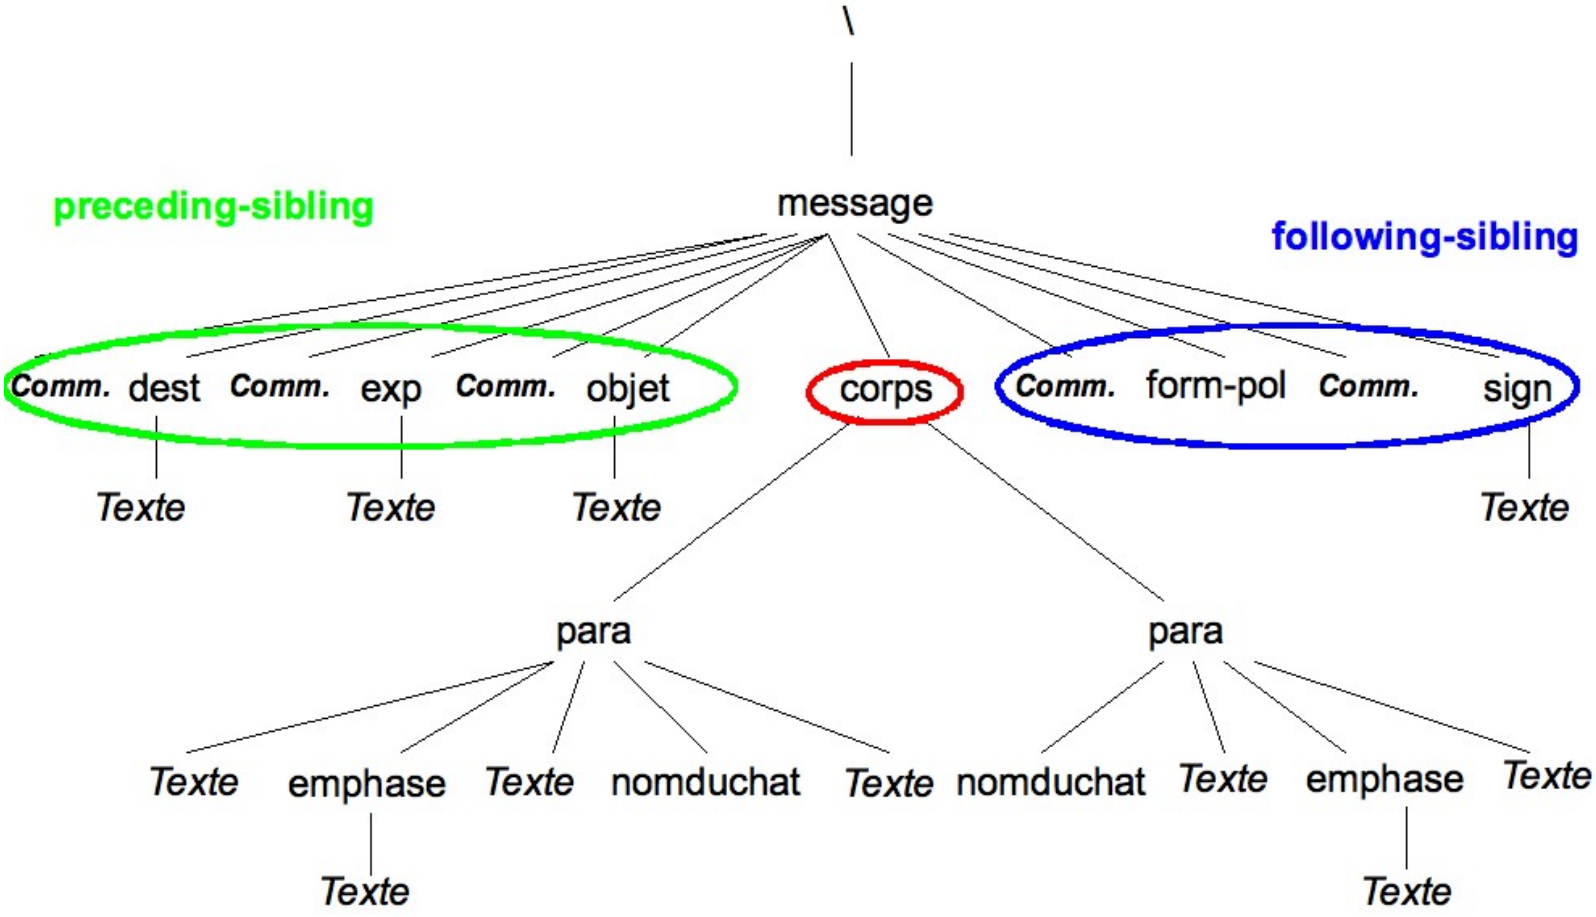
\
preceding-sibling
message
following-sibling
Comm.
dest
Comm.
exp
Comm.
objet
corps
Comm.
form-pol
Comm.
sign
Texte
Texte
Texte
Texte
para
para
Texte
emphase
Texte
nomduchat
Texte
nomduchat
Texte
emphase
Texte
Texte
Texte

# Axes

- following :
  - dans l'arbre, les noeuds qui se trouvent à droite du chemin qui va de la racine au noeud-contexte ;
  - dans le document, les éléments dont la balise ouvrante se situe au-dessous de la balise fermante du noeud-contexte
- following-sibling : les noeuds frères qui suivent le noeud contextuel
- preceding :
  - dans l'arbre, les noeuds qui se trouvent à gauche du chemin qui va de la racine au noeud-contexte ;
  - dans le document, les éléments dont la balise fermante se situe au-dessus de la balise ouvrante du noeud-contexte
- preceding-sibling : frères qui précèdent

# Se déplacer dans les arbres

- En l'absence de précision de l'axe, c'est child qui est choisi

  `fiche-technique/ingredient`

  est équivalent à

  `child::fiche-technique/child::ingredient`

# Tests de noeuds

Les tests de noeuds possibles :

- / : le noeud racine (pas l'élément document)
- node() : tout noeud sauf le noeud racine et les attributs
- * : dans l'axe des attributs, tout attribut, dans l'axe des espaces de noms, tout espace de noms, dans les autres axes, tout élément
- un_nom : un_nom d'un attribut, d'un préfixe d'espace de noms ou d'un élément, suivant l'axe

# Tests de noeuds

- text() : tout noeud de texte
- processing-instruction() : toute instruction de traitement
- processing-instruction('une_instruct') : l'instruction de traitement une_instruct
- comment() : tout noeud commentaire

# Raccourcis

Les raccourcis :

- *
- @ : désigne les attributs en l'absence de qualificateur d'axe.

  @* est équivalent à attribute : :*
  @priorité est un attribut de nom priorité
- . : le noeud lui-même (équivalent à self : :*)
- .. : le noeud parent
- // : équivalent à `/descendant-or-self::node()/`

# Se déplacer dans les arbres

**Exemples**

- `//para` est équivalent à `/descendant-or-self::node()/child::para`
- `//para[1]` n'est pas équivalent à `/descendant::para[1]`
- `.//para` est équivalent à `self::node()/descendant-or-self::node()/child::para`

# Exemple

```
<?xml version="1.0" encoding="iso-8859-1" ?>
<message priorité="importante">
  <!-- le destinataire --><dest>M. Dupont</dest>
  <!-- l'expéd. --><exp>Agence Matous Heureux</exp>
  <!-- le sujet --><obj>alimentation du chat</obj>
  <corps>
    <para>Conformément à vos instructions, je donne
<emphase>trois</emphase> rations de croquettes
par jour à <nomduchat />.</para>
    <para><nomduchat /> a cependant
pris <emphase>deux</emphase> kilos pendant
les vacances.</para>
  </corps>
  <!-- pour finir --><form-pol style="simple"/>
  <!-- signature --><sign>Melle. Dumoulin</sign>
                  e>
```

# Axes

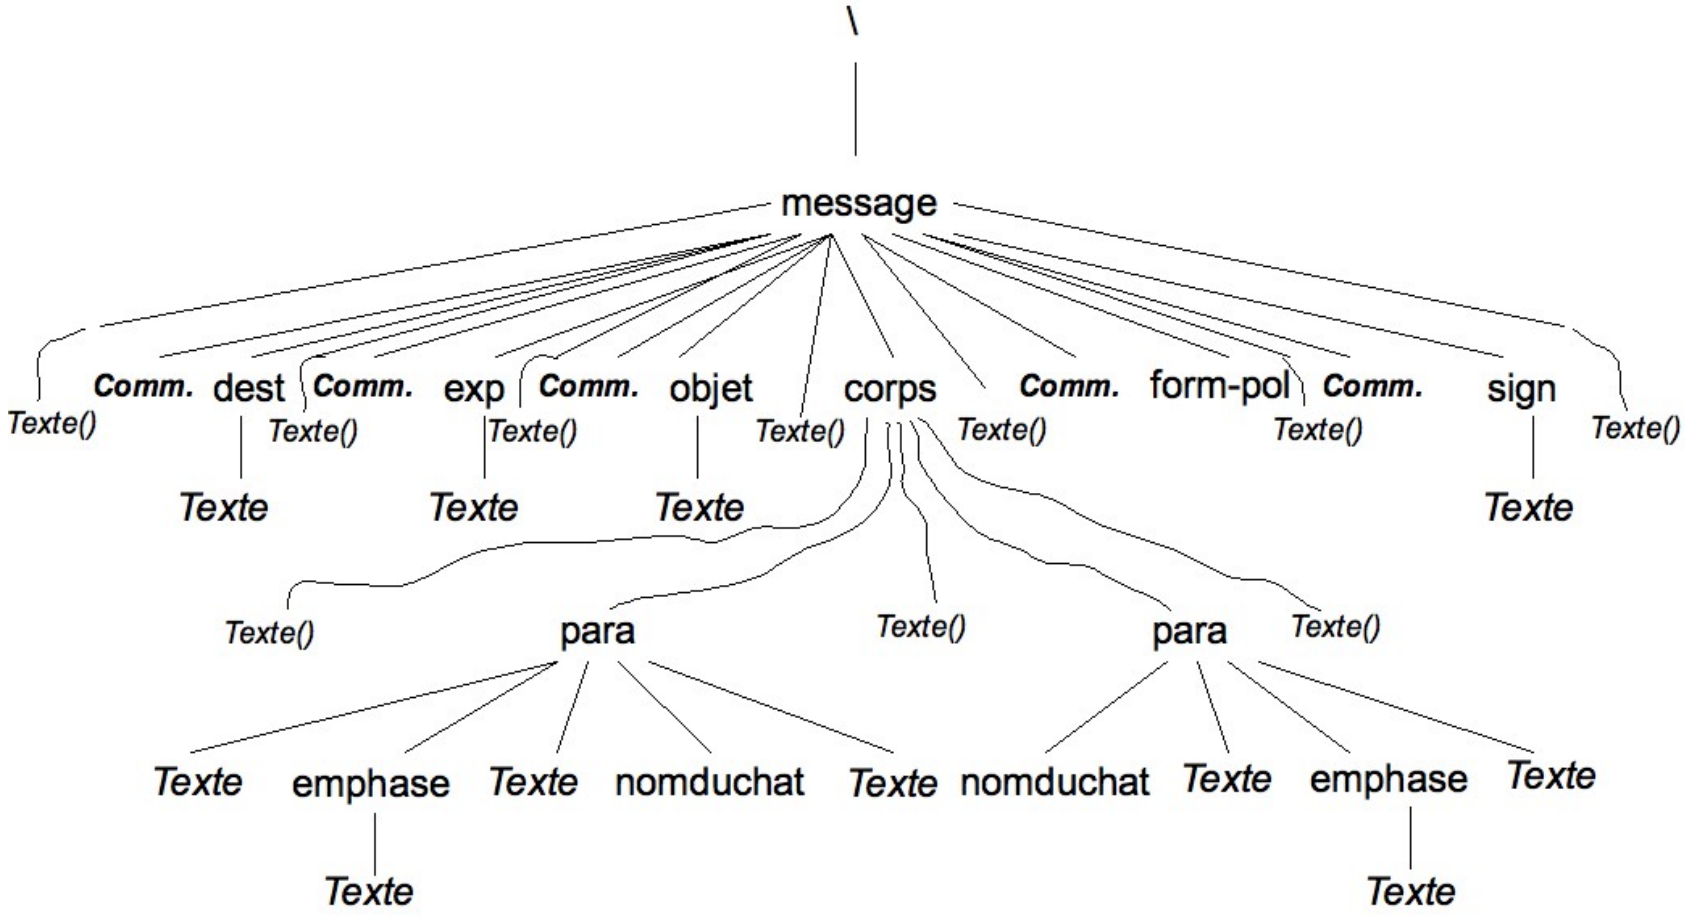


*Texte() : noeud blanc – le texte ne contient que des séparateurs (espaces, retours à la ligne, tabulations, ...)*

# Exemples !

Le noeud-contexte est corps.

Que retourne ...

| | |
|---|---|
| `child::node()` | `child::*` |
| `parent::*` | `descendant-or-self::text()` |
| `parent::message` | `ancestor-or-self::corps` |
| `parent::para` | `ancestor-or-self::/` |
| `self::para` | `descendant::comment()` |
| `preceding-sibling::*` | `following-sibling::node()` |
| `descendant::para` | `descendant::para[child::nomduchat]` |
| `self::corps` | `descendant::para/child::nomduchat` |

# Exemples !

Le noeud-contexte est corps.

- `child::node()` : tous les noeuds fils de `corps`, i.e. ici les deux noeuds `para` et trois noeuds blancs
- `child::*` : `*` est plus restrictif que `node()` puisqu'en ne conservant que les éléments, il oublie les commentaires et les instructions de traitements, et les zones de texte. Ici, il n'y a plus que les deux noeuds `para`.
- `parent::*` : le noeud père, c'est-à-dire le noeud `message`
- `descendant-or-self::text()` : toutes les zones de texte en-dessous de corps (y compris les noeuds blancs)

# Exemples !

- `parent::message` : même chose, retourne le noeud `message`
- `ancestor-or-self::corps` : le noeud `corps` lui-même
- `self::corps` : idem
- `parent::para` : l'ensemble vide !
- `ancestor-or-self::/` : le noeud racine
- `self::para` : l'ensemble vide !
- `descendant::comment()` : les commentaires plus bas (s'il y en avait)

# Exemples !

- `preceding-sibling::*` : l'objet, le destinataire, et l'expéditeur
- `following-sibling::node()` : la signature, la formule de politesse et les deux commentaires, ainsi que les zones de textes blancs
- `descendant::para` : les deux noeuds `para`
- `descendant::para[child::nomduchat]` : les `para` qui ont le nom du chat dans leur texte, à ne pas confondre avec ...
- `descendant::para/child::nomduchat` : qui retourne les noeuds `nomduchat`

# Prédicats

Le dernier filtre est l'évaluation d'une expression dont le résultat est converti en un booléen.

Principales règles :

- si c'est un nombre : il est comparé à la position du noeud dans le contexte ;
  `para[1]` est équivalent à `child::para[position()=1]` i.e. le premier fils `para` du noeud contextuel (s'il existe)
- si c'est une chaîne de caractères : faux si c'est la chaîne vide, vrai sinon ;
- si c'est un ensemble de noeuds : faux si c'est un ensemble vide, vrai sinon.

# Expressions

- les opérateurs logiques `or`, `and` (il existe une fonction `not(Expr)`)
- les opérateurs de comparaison =, !=, <, <=, >, >=
- les opérateurs arithmétiques +, -, mod, div, *
- l'opérateur union pour des ensembles de noeuds ||

# Fonctions

- pour convertir en booléen `boolean(expr)`
- fonctions sur des ensembles de noeuds :
  - `number last()` : taille du contexte
  - `number position()` : indice du noeud sélectionné dans le contexte
  - `number count(node-set)` : taille de l'ensemble de noeuds donné en paramètre
  - `node id(string)` : le noeud dont l'identifiant est donné en paramètre

# Fonctions

- pour convertir en chaine de caractères : `string(node ou node-set)`
- fonctions sur des nombres :
  - `number sum(node-set)`
  - `number floor(number)`
  - `number ceiling(number)`
  - `number round(number)`

# Fonctions

- fonctions sur des chaînes de caractères :
  - `concat(chaine, chaine, ...)`
  - `normalize-space(chaine)`
  - `substring(chaine, debut, taille)`
  - `substring-after(chaine, sous-chaine)`
  - `substring-before(chaine, sous-chaine)`
  - `contains(chaine,sous-chaine)`
  - `starts-with(chaine,prefixe)`
  - `string-length(chaine)`