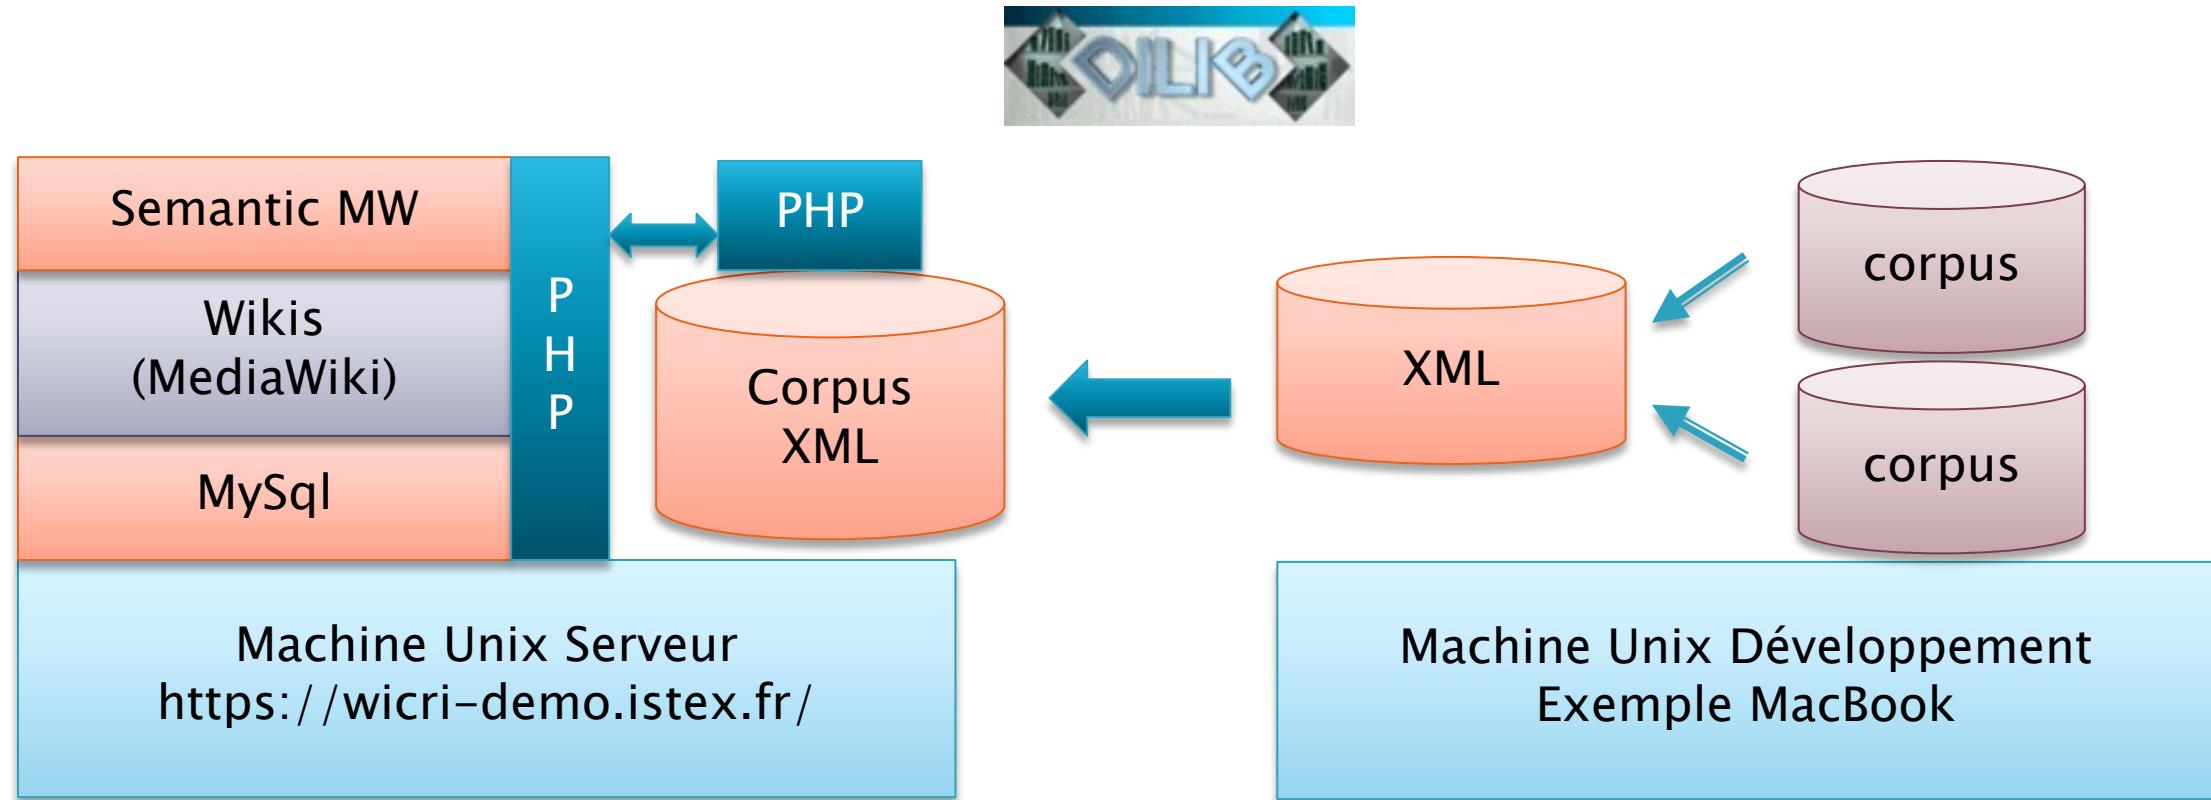


# Machine serveur – machine développement

## Unix, langage C, PHP, XML, JSON, etc...



# Dilib, une boîte à outils Sxml

- ▶ SXML : XML lite (mais JSON+)
  - Compatible avec les outils Unix
    - Un document = Une ligne Unix
- ▶ Origine : Un Lego pour les corpus
  - 1990 : Ilib : ISO 2709 (MARC, Pascal...)
- ▶ Formats MARC



210 \$a Paris \$c Dunod \$d 1988

```
<unimarc>...<f210><sa>Paris</sa><sc>Dunod</sc>
  <sd>1988</sd><f210>...</unimarc>
```

- ▶ Fichiers inverses

```
<idx><loc>Paris</loc><f>2</f>
  <l><e>0023</e><e>4123</e></l></idx>
```

```
<index>
  <kw>Requiem</kw>
  <list>
    <item>004321</item>
    <item>012345</item>
  </list>
  <f>2</f>
</index>
```

# Préfiguration : analyseurs syntaxiques (Lex)

The image shows a musical score for 'TRIO.' featuring two staves of music. The top staff is in common time (4/4), key f major, with notes in f, f', c, g, and ees. The bottom staff is also in common time (4/4), key f major, with notes in f, f', c, and ees. The lyrics 'Nous voyons que les hom-mes font tous ver - tu d'aimer' are written below the staves.

```
\time 4/4 \key f \major
r4 f4 c' f,4
c'4 g f2
f4 f' f c
ees4 f c2
```

```
%%
a      printf ("fis");
bes   printf ("g");
c      printf ("a");
d      printf ("b");
e      printf ("cis");
ees   printf ("c");
f      printf ("d");
g      printf ("e");
%%
main()
{
    yylex();
}
```

Source gallica.bnf.fr

The image shows a single staff of music in common time (4/4), key f major, with notes in f, f', c, and ees. The lyrics 'Nous voyons que les hom-mes font tous ver - tu d'aimer ;' are written below the staff.

# XML et Unix : variante Sxml

## ▶ Unix :

- un système pour manipuler des lignes de texte
- Exemple : combien de lignes contiennent le terme Europium dans mon article ?

```
cat monDoc | grep [Ee]uropium | wc
```

## ▶ Stream Xml

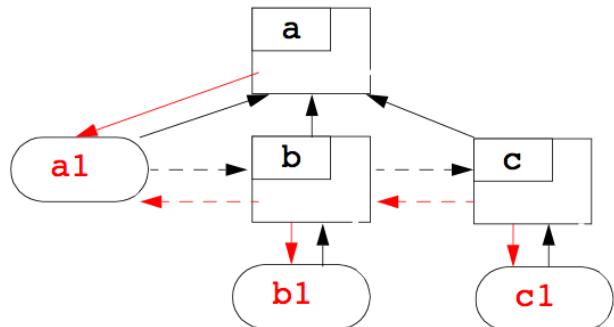
- Un document XML =
  - une ligne (pas de saut de lignes)
- Combien de documents contiennent le terme Europium dans mon corpus ?

```
cat monCorpus | grep [Ee]uropium | wc
```

# DILIB – parser Sxml

## ▶ Document Object Model (DOM)

<a>a1<b>b1</b><c>c1</c></a>



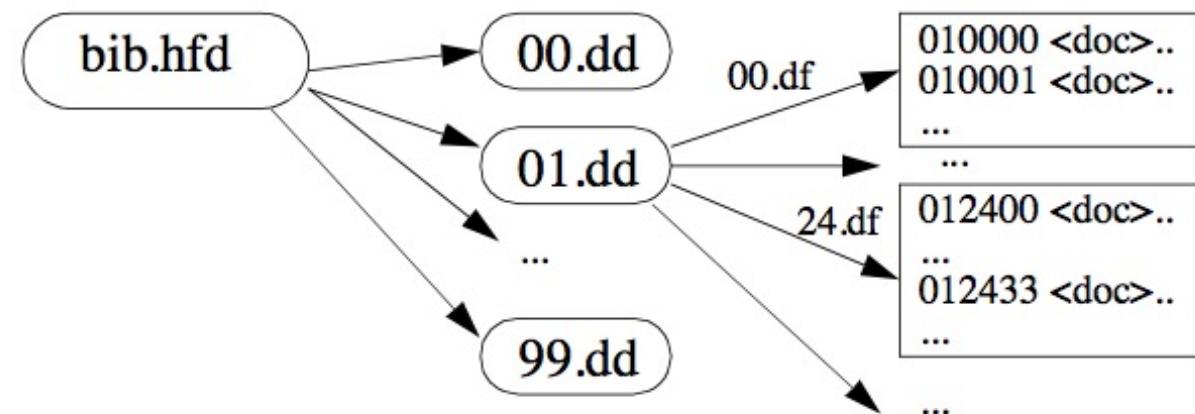
```
/* création de <a><b>b1</b><c>c1</c></a> */  
#include "SXmlNode.h"  
main()  
{  
    SXmlNode *root;  
    root = SxmlElementCreate("a");  
    SxmlAppendChild (root, SxmlLeafCreate("b", "b1"));  
    SxmlAppendChild (root, SxmlLeafCreate("c", "c1"));  
    SxmlPrint(root);  
    putchar('\n');  
    exit(0);  
}
```

# Dilib – Parser DOM

- ▶ Parser classique
  - Libxml, Java, php...
  - Manipule un (ou quelques) éventuellement gros documents.
- ▶ Parser Dilib Sxml
  - Manipule de très grandes collections de petits documents,
  - Plus souple d'emploi (espaces de nom)
  - Extensions possibles (types numériques)
  - Peu de restrictions / norme
  - Très peu de restrictions via filtres
- ▶ La philosophie Dilib est indépendante de Dilib

# Dilib HFD

- ▶ Architecture XML pour construire des systèmes de recherche d'information en kit.
- ▶ Hierarchy File Document
  - $1.000.000 = 100 * 100 * 100$
  - 012433 → 01 / 24 / 33
  - bib.hfd/01.dd/24.fd



# DILIB – HFD – Fichiers inverses

Un exemple Serveur d'exploration sur l'Europium à partir du wiki Wicri/Terre

<http://ticri.univ-lorraine.fr/Wicri/Terre/>  
corpus/Europium/EuropiumV1/Data/Main/Exploration/  
AffRegion.i.hfd/00.dd/00.df

```
000000 <idx><kw>Alsace</kw><lc>alsace</lc><f>3</f><l><e>000070</e><e>000136
          </e><e>000175</e></l></idx>
000001 <idx><kw>Angleterre</kw><lc>angleterre</lc><f>7</f>
          <l><e>000046</e><e>000091</e><e>000107</e><e>000183</e>
          <e>000221</e><e>000233</e><e>000251</e></l></idx>
000002 <idx><kw>Aquitaine</kw><lc>aquitaine</lc><f>1</f><l><e>000117</e></l></idx>
000003 <idx><kw>Bavière</kw><lc>bavière</lc><f>1</f><l><e>000173</e></l></idx>
000004 <idx><kw>Berlin</kw><lc>berlin</lc><f>2</f>
          <l><e>000005</e><e>000231</e></l></idx>
```

# Complémentarité Wiki -Sxml

## ▶ Commandes liées aux tables

```
WicriGetPage -l wicri-afrique.fr -p "Wicri:Liste de localisation de pays d'Afrique" \
| MediaWikiCleanTable
| MediaWikiTable2SxmlRowCol
| MediaWikiTableTransformCol -11 -E2
| TeiTableRegionFromWiki
```



```
<figure>
<link target="Ghana"/>
<head offset="se">Ghana</head>
<geo latitude="7.68" longitude="-0.98">7.68 -0.98</geo>
</figure>
```