

Introduction pratique à SGML

Michel Goossens / CERN

Nanterre le 19 janvier 1995

- Pourquoi SGML ?
- Qui utilise SGML ?
- Les principes de base de SGML.
- La fonction et la structure d'une DTD.
- Quelques outils SGML.
- Autres normes pour les documents électroniques.

Pourquoi SGML ?

- passage support papier à support électronique ;
- grande masse d'informations structurées (annuaires, dictionnaires, recueils juridiques) ;
- gestion des ces informations ;
- actualisation en permanence ;
- multiples représentations à partir d'un même document source (liste d'adresses, CD-ROM, minitel, WWW, base de données).

Points forts d'un balisage SGML

- une amélioration de la qualité des sources des documents ;
- une rationalisation dans le traitement du document, surtout un cycle de travail plus rapide ;
- une réduction du coût des publications ;
- la possibilité de réutilisation de l'information, d'où une plus-value (imprimées, hypertexte, bases de données).

La naissance de SGML

- une représentation de la structure logique des documents est essentielle pour les traiter électroniquement ;
- pour pouvoir échanger les documents il faut un langage commun ;
- en octobre 1986 ISO adopta officiellement SGML (*Standard Generalized Markup Language*), le langage standard de balisage généralisé ;
- adopté et utilisé par plusieurs organismes et entreprises nationaux et internationaux et par les développeurs de logiciels ;
- occupe déjà une place importante dans le monde de l'édition.

Qui utilise SGML ?

- l'association des éditeurs américains (AAP) (trois types de documents : le livre, la publication en série et l'article) ;
- l'AAP et l'EPS (European Physical Society) ont développé ISO 12083 (tableaux et formules mathématiques) ;
- CALS (*Computer-aided Acquisition and Logistic Support*) du département de la défense américaine (DoD) ;
- l'Office des Publications de la Communauté Européenne (FORMEX) ;
- l'association des éditeurs allemands (Börsenverein des Deutschen Buchhandels) ;
- la British Library avec « SGML : Guidelines for editors and publishers » et « SGML : Guidelines for authors » ;

Qui utilise SGML (suite)?

- en France, le Syndicat national de l'édition et le Cercle de la librairie ont défini une application pour les éditeurs français ;
- l'Office des Publications de ISO (Genève) et le HMSO pour les brevets (Angleterre) ;
- Oxford University Press et Virginia Polytechnic (PhD, USA) ;
- le Text Encoding Initiative (textes classiques et commentaires) ;
- la plupart des manuels techniques, avec par ex. DTD DocBook ou autres, utilisés par IBM, HP, OSF, O'Reilly, etc.
- les modules SGML entrée/sortie sur des systèmes de traitement de texte ou de base de données (Frame, Interleaf, Microsoft, Oracle, Wordperfect) ;

Qui utilise SGML (suite) ?

- McGraw-Hill (Encyclopedia of Science and Technology) ;
- l'industrie électronique (Pinnacle), l'industrie aéronautique, les compagnies aériennes (Boeing, Airbus, Rolls Royce, Lufthansa, etc.) et l'industrie pharmaceutique ;
- les agences de presse ;
- les éditeurs ou systèmes de présentation SGML (Arbortext, EBT, Exoterica, Grif, Softquad) ;
- HTML et WWW (évidemment !).

Principes de base de SGML

- une méthode normalisée pour représenter l'information contenue dans un document ;
- indépendant des systèmes de saisie et de traitement ;
- indépendant de la forme physique finale ;
- principe de *balisage* logique généralisé ;
- ne définit pas le langage de balisage ;
- un *méta-langage* pour construire plusieurs langages de balisage.

Le balisage spécifique

TEX

```
\vfil\eject
```

```
\par\noindent
```

```
{\bf Chapitre 2 : Titre du chapitre}
```

```
\par\vskip\baselineskip
```

Script

```
.pa
```

```
.bd Chapitre 2 : Titre du chapitre
```

```
.sp
```

Le balisage spécifique (suite)

- balisage de type « présentation » : caractères de contrôle mêlés aux caractères (imprimables) du document. (fin de ligne, coupures de page, contrôle d'espacements...);
- ces caractères sont non-standard ;
- difficile d'échanger des documents entre différents systèmes ;
- balisage propre à une représentation donnée et une présentation physique ;
- facile à afficher et imprimer ;
- n'autorise que des traitements limités.

Balises génériques ou logiques

TEX

```
\chapter{Titre du chapitre}
```

```
\par
```

HTML (SGML)

```
<H1>Titre du chapitre</H1>
```

```
<P>
```

Balises génériques ou logiques (suite)

- augmenter les possibilités de traitement ;
- faire abstraction de tout aspect physique ;
- décrire la fonction logique des éléments (titre, sections, paragraphes, tableaux, références bibliographiques...);
- spécifier leurs relations mutuels.

Balisage logique généralisé

Le *marquage* de la structure d'un document, s'effectue en deux temps :

1. la définition de l'ensemble des balises pour identifier les éléments d'un document et les règles formelles qui décrivent sa structure (c'est le rôle de la DTD) ;
2. l'introduction du balisage dans le document lui-même, selon les principes de cette définition formelle.

```
<article>
```

```
<tit>Une introduction à SGML</tit>
```

```
<sec>Principes de base de SGML</sec>
```

```
<P> ...
```

```
<ssec>Le balisage logique généralisé</ssec>
```

```
<P> ...
```

Balisage logique généralisé (suite)

Plusieurs documents spécifiques peuvent appartenir à une seule classe de documents construits selon la même structure générique.

Article A	Article B
Titre	Titre
Section 1	Section 1
Sous-section 1.1	Sous-section 1.1
Sous-section 1.2	Sous-section 1.2
Section 2	Sous-section 1.3
Section 3	Section 2
Sous-section 3.1	Sous-section 2.1
Sous-section 3.2	Sous-section 2.2
Sous-section 3.3	Bibliographie
Sous-section 3.4	
Bibliographie	

La définition d'une classe de document (DTD)

La DTD définit :

- le *nom* des éléments qui peuvent être utilisés ;
- le *contenu* de chaque élément ;
- *combien de fois* et dans quel *ordre* les éléments peuvent apparaître ;
- si une balise de début (fin) peut être *omise* ;
- les *attributs* éventuels et leur valeurs par défaut ;
- le nom des *entités* qui peuvent être utilisées.

La structure de la DTD

La DTD de HTML2 contient deux parties :

1. partie « système » : le jeu de caractères utilisé et les options autorisées, par ex. OMITTAG ;
2. partie « déclaration » de la classe de document HTML : les éléments, attributs et entités possibles.

Les déclarations ont la forme :

```
<! ... >
```

Une section marquée a la forme :

```
<![ mot_clé [ ... ] ] >
```

La structure de la DTD (suite)

Les commentaires

```
<!-- texte du commentaire -->
```

La déclaration d'un élément

- nom de l'élément ;
- la minimisation possible ;
- le *modèle de contenu*.

```
<!ELEMENT (OL|UL) - - (LI)+>
```

```
<!ELEMENT LI - 0 %flow>
```

La structure de la DTD (suite)

Symboles d'ordre et de choix

,	« et » ordonné ;	+	1 fois ou plus ;
&	« et » non ordonné ;	?	0 ou 1 fois ;
	« ou » exclusif ;	*	0 fois ou plus.

```
<!ELEMENT DL - - (DT*, DD?)+>
```

```
<!ENTITY % head.content "TITLE & ISINDEX? & BASE? & META*  
%head.nextid %head.link">
```

```
<!ELEMENT HEAD 0 0 (%head.content)>
```

```
<!ELEMENT FORM - - %body.content  
- (FORM) + (INPUT | SELECT | TEXTAREA)>
```

La structure de la DTD (suite)

Type de caractères utilisés

PCDATA *parsed character data* ou données textuelles analysées.

```
<!ELEMENT TITLE - - (#PCDATA)>
```

RCDATA *replaceable character data* ou données textuelles remplaçables.

CDATA *character data* ou données textuelles.

```
<!ELEMENT TEL CDATA>
```

ANY L'élément peut contenir du matériel de type PCDATA ou tout autre élément défini dans la DTD.

EMPTY L'élément a un *contenu vide*.

```
<!ELEMENT IMG - 0 EMPTY>
```

La structure de la DTD (suite)

Les attributs

Une déclaration d'attribut comporte :

- le nom de l' (des) élément(s) auquel elle se rapporte ;
- le nom de l'attribut ;
- soit le *type de l'attribut*, indiqué par un mot-clé soit, entre parenthèses, la liste des valeurs que peut prendre cet attribut ;
- une valeur par défaut (sous la forme d'une des valeurs autorisées, spécifiée entre guillemets, ou d'un mot-clé).

```
<!ATTLIST élément_qualifié attribut (valeurs) "défaut">
```

La structure de la DTD (suite)

Les mots-clé pour les types d'attribut

CDATA	données textuelles (caractères quelconques) ;
ENTITY(IES)	nom(s) d'entité(s) générale(s) ;
ID	l'identificateur SGML d'un élément ;
IDREF(S)	valeur(s) d'appel d'identificateur(s) d'élément ;
NAME(S)	nom(s) SGML ;
NMTOKEN(S)	unité(s) lexicale(s) nominale(s) ;
NOTATION	nom de notation ;
NUMBER(S)	nombre(s) ;
NUTOKEN(S)	unité(s) lexicale(s) numérique(s).

La structure de la DTD (suite)

Les mots-clé pour les valeurs par défaut

- | | |
|-----------|--|
| #FIXED | L'attribut a une valeur fixe, et ne peut prendre que cette valeur ; |
| #REQUIRED | Une valeur doit obligatoirement être spécifiée par l'utilisateur ; |
| #CURRENT | Si une valeur n'est spécifiée, la valeur par défaut utilisée sera la dernière valeur spécifiée ; |
| #CONREF | La valeur sera utilisée pour les références croisées ; |
| #IMPLIED | Si une valeur n'est spécifiée, le système de traitement définira une valeur. |

La structure de la DTD (suite)

```
<!ATTLIST DL COMPACT (COMPACT) #IMPLIED>
```

```
<!ATTLIST PRE WIDTH NUMBER #IMPLIED>
```

```
<!ATTLIST IMG SRC      %URI;          #REQUIRED
                ALT      CDATA         #IMPLIED
                ALIGN    (top|middle|bottom) #IMPLIED
                ISMAP    (ISMAP)       #IMPLIED >
```

Les entités

Des entités sont utiles dans plusieurs circonstances :

- notations raccourcies pour des suites de caractères saisies fréquemment (entités générales) :

```
<!ENTITY GUT "GUTenberg">
```

- notations pour saisir des caractères spéciaux, accents ou symboles (entités générales et caractères).

```
<!ENTITY amp CDATA "&#38;" -- << et >> commercial "&"-->
```

L'ISO a défini plusieurs ensembles d'entités caractères standardisés, les symboles graphiques, mathématiques, etc.

- l'inclusion de fichiers externes (entités externes) ;

```
<!ENTITY article SYSTEM "/usr/g/goossens/sgmlart.sgml" >
```

Les entités (suite)

Il faut saisir les entités textuellement en faisant attention à la présence de majuscules ou minuscules. La casse du nom des éléments et des attributs n'a pas d'importance.

appels d'entités

&GUT;

Les entités paramètres

Utilisées à l'intérieur d'une DTD pour augmenter la modularité de la définition des différents éléments de la DTD.

```
<!ENTITY % heading "H1|H2|H3|H4|H5|H6">
```

```
<!ENTITY % list " UL | OL | DIR | MENU " >
```

```
<!ENTITY % text "#PCDATA | A | IMG | BR">
```

```
<!ELEMENT ( %heading ) - - (%text;)+>
```

Quelques outils SGML

- SGML est maintenant très répandu ;
- de multiples solutions commerciales existent ;
- augmenter la productivité, le confort et la convivialité d'utilisation ;
- quelques outils intéressants et disponibles publiquement.

Valider un document SGML avec `sgmls`

- `sgmls` est un programme d'analyse (*parser*) disponible publiquement ;
- développé par James Clark en se basant sur un programme antérieur `arcsgml` Charles Goldfarb ;

```
sgmls [-deglprsuv] [-cfichier] [-inom] [nom_de_fichier]
```

Valider un document SGML avec sgmls (suite)

```
<HTML>
<!-- Un commentaire -->
<HEAD>
  <TITLE>Document test HTML</TITLE>
</HEAD>
<!-- Début du corps du document -->
<BODY>
<DL>
  <DT>terme 1<DD>donnée 1
  <DT>terme 2<DD>donnée 2
  <DT>terme 3
  <DT>terme 4<DD>donnée 4<DD>donnée 4 bis
</DL>
</BODY>
</HTML>
```

Valider un document SGML avec sgm1s (suite)

(HTML	(DD	(DT
(HEAD	-donnée 1\n	-terme 4
(TITLE)DD)DT
-Document test HTML	(DT	(DD
)TITLE	-terme 2	-donnée 4
)HEAD)DT)DD
(BODY	(DD	(DD
ACOMPACT IMPLIED	-donnée 2\n	-donnée 4 bis
(DL)DD)DD
(DT	(DT)DL
-terme 1	-terme 3\n)BODY
)DT)DT)HTML

Valider un document SGML avec sgm1s (suite)

Un document contenant une erreur :

```
<HTML>                               ligne 453
<BODY>                                454
  <P>texte dans un paragraphe         455
</BODY>                                456
</HTML>                                457
```

Valider un document SGML avec sgmls (suite)

```
AVERSION CDATA -//IETF//DTD HTML//EN//2.0
```

```
(HTML
```

```
(HEAD
```

```
sgmls: SGML error at a, line 454 at ">":
```

```
        BODY element not allowed at this point in HEAD element
```

```
(P
```

```
-texte dans un paragraphe
```

```
)P
```

```
sgmls: SGML error at a, line 457 at ">":
```

```
        HEAD element ended prematurely; required subelement omitted
```

```
)HEAD
```

```
sgmls: SGML error at a, line 457 at ">":
```

```
        HTML element ended prematurely; required BODY omitted
```

```
)HTML
```

Valider un document SGML avec sgm1s (suite)

Un autre document contenant une erreur :

<HTML>	ligne 453
<HEAD>	454
<TITLE>titre</TITLE>	455
</HEAD>	456
<BODY>	457
	458
</BODY>	459
</HTML>	

Valider un document SGML avec sgm1s (suite)

```
(HTML
```

```
(HEAD
```

```
(TITLE
```

```
-titre
```

```
)TITLE
```

```
)HEAD
```

```
(BODY
```

```
)BODY
```

```
sgm1s: SGML error at a, line 458 at ">":
```

```
    Out-of-context LI start-tag ended HTML document element
                                                (and parse)
```

```
)HTML
```

Outils d'analyse de documents SGML

Earl Hook a développé plusieurs outils SGML écrits en perl, permettant d'analyser un document ou DTD SGML :

- `dtd2html` produit un document HTML à partir d'une DTD SGML qui permet une navigation hypertexte à travers une DTD SGML ;
- `dtddiff` compare deux DTDs et montre les différences éventuelles ;
- `dtdtree` produit une visualisation de l'arborescence hiérarchique caractérisant les relations entre les différents éléments définis dans une DTD ;
- `stripsgml` enlève les balises SGML d'un texte et essaie de traduire les appels d'entités de caractères standard en ASCII.

Étudier la structure d'une DTD — dtdtree

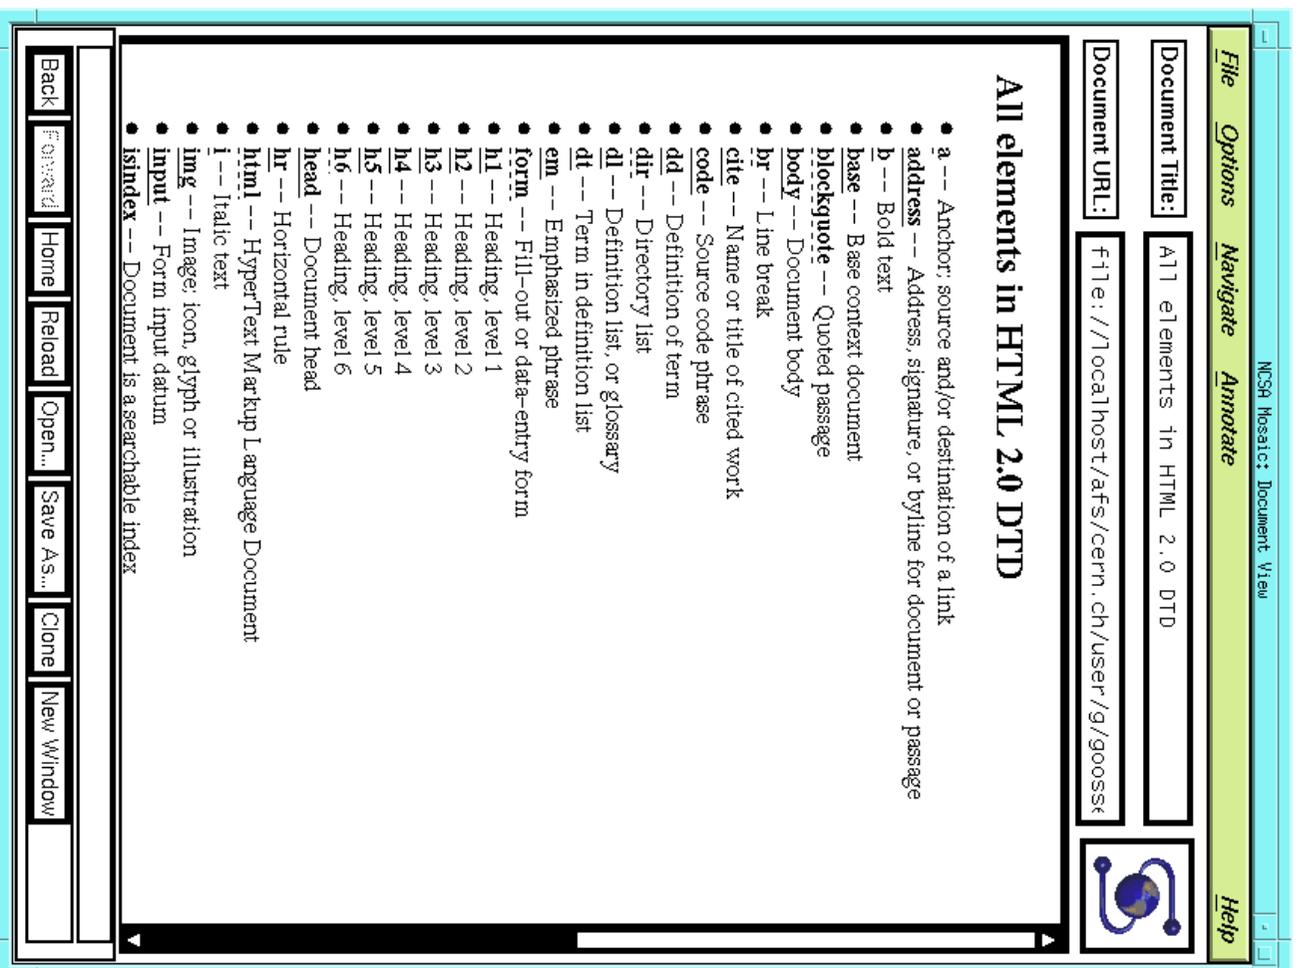
```

HTML
|
|_body
|  |
|  |_#PCDATA
*****
|  |_dl
|  |  |
|  |  |_dd
|  |  |  |
|  |  |  |_#PCDATA
|  |  |  |_a ...
|  |  |  |_b ...
|  |  |  |_blockquote
|  |  |  |_br ...
|  |  |  |_cite ...
|  |  |  |_code ...
|  |  |  |_dir ...
|  |  |  |_dl ...
|  |  |  |_em ...
|  |  |  |_form ...
|  |  |  |_i ...
|  |  |  |_img ...
|  |  |  |_isindex ...
|  |  |  |_kbd ...
|  |  |  |_listing ...
|  |  |  |_menu ...
|  |  |  |_ol ...
|  |  |  |_p ...
|  |  |  |_pre ...
|  |  |  |_samp ...
|  |  |  |_strong ...
|  |  |  |_tt ...
|  |  |  |_ul ...
|  |  |  |_var ...
|  |  |  |_xmp ...
|  |  |  |_dt
|  |  |  |_#PCDATA
|  |  |  |_a ...
|  |  |  |_b ...
|  |  |  |_br ...
|  |  |  |_cite ...
|  |  |  |_code ...
|  |  |  |_em ...
|  |  |  |_i ...
|  |  |  |_img ...
|  |  |  |_kbd ...
|  |  |  |_samp ...
|  |  |  |_strong ...
|  |  |  |_tt ...
|  |  |  |_var ...

```

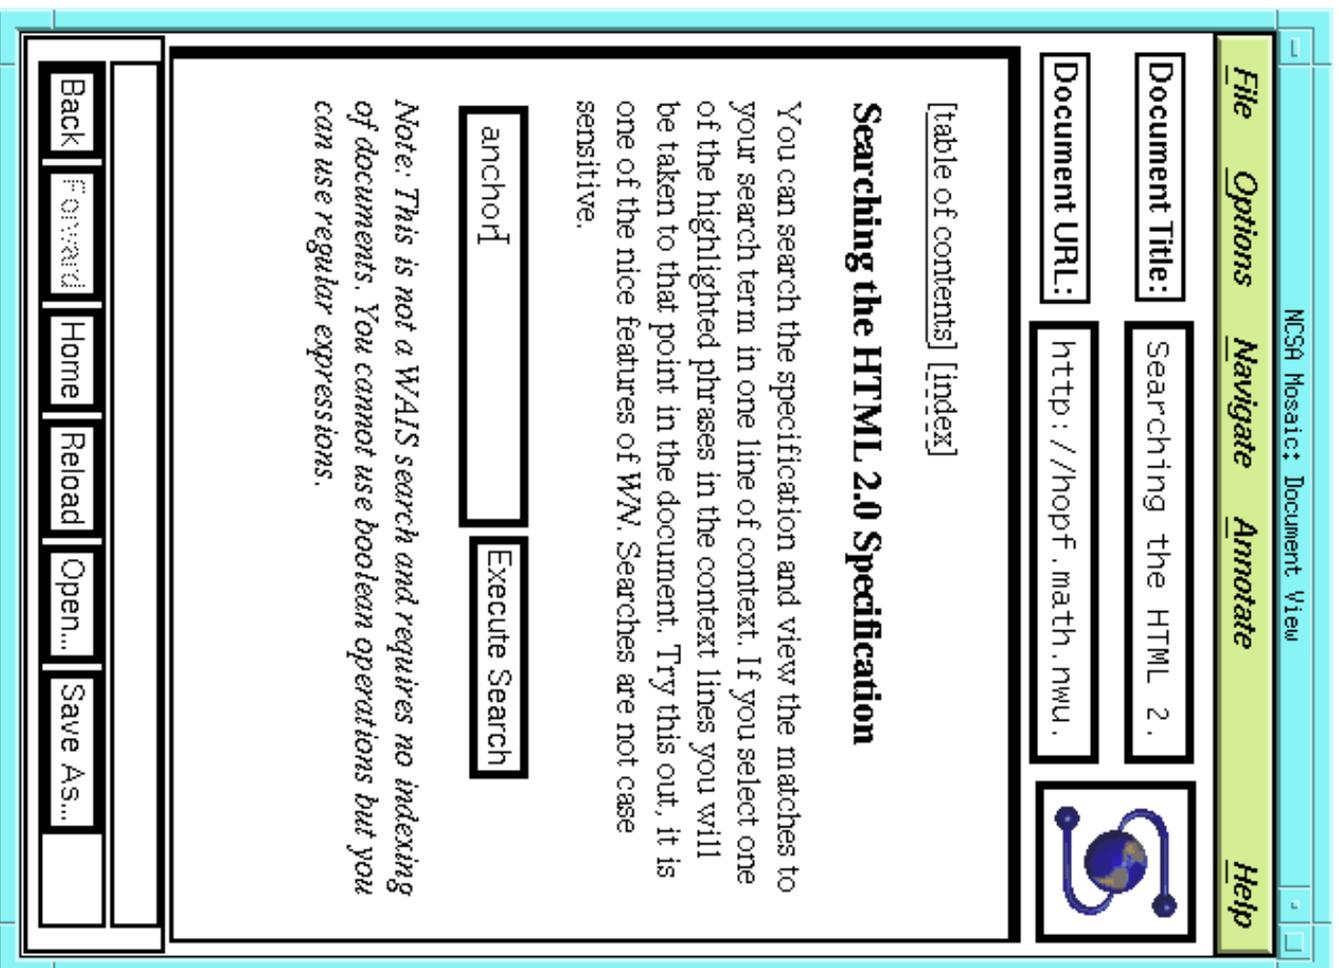
Documenter une DTD – dtd2html

Description hypertexte des éléments d'une DTD (HTML2) visualisée avec mosaic.



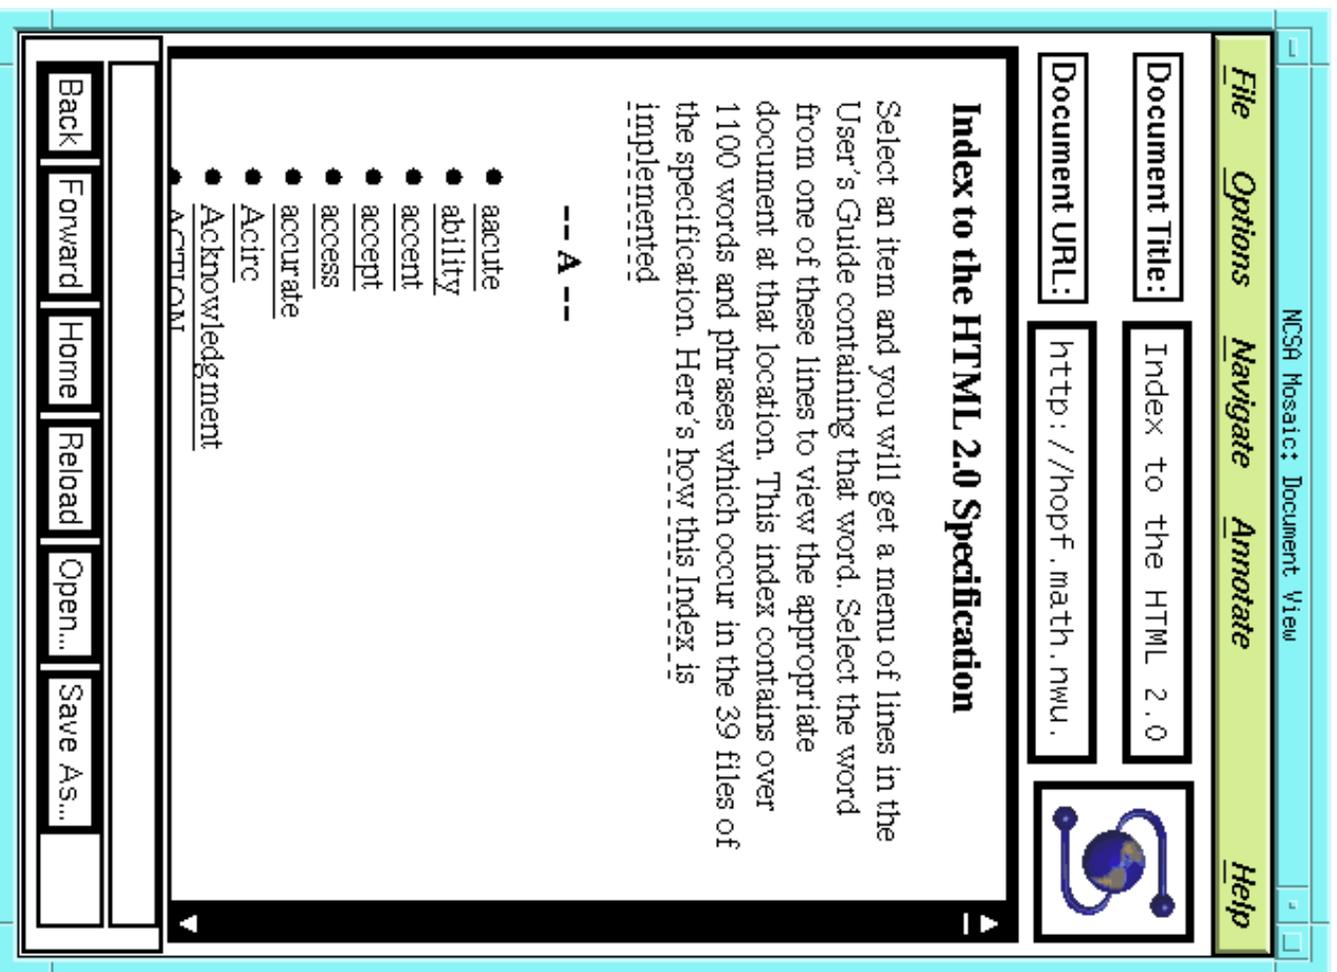
Recherche d'information

Un moteur de recherche par expression régulière.



Recherche en index

Index de 1100 mots et phrases de la DTD HTML2.



Autres normes

- ISO 8879 le standard SGML ;
- ISO 9096 (SDIF) format pour échanger des documents SGML ;
- ISO 10744 (Hytime) formalisme pour la représentation hypermedia de documents.
- ISO-DIS 10179 (DSSSL pour *Document Style Semantics and Specification Language*) les concepts et actions nécessaires pour passer de la structure logique d'un document à sa mise en forme physique.
- ISO-DIS 10180 (SPDL pour *Standard Page Description Language*) description des documents dans leur forme finale, entièrement composée, non révisable (presque du PostScript) ;
- ISO 9541 le standard des polices de caractères. Méthode pour nommer et grouper les glyphes ou collections de glyphes indépendante de tout codage spécifique.