

COMPLÉMENTS FORMATS DE FICHIERS, INTERNET, RECHERCHE D'INFORMATION

Stage – Semaine 5

RAPPEL : AU SEMESTRE 2 !

Au **semestre 2**, vous serez en niveau « Standard ». Ce niveau reprend le contenu du stage pour aller ensuite au-delà.

En fonction de votre résultat, vous aurez 6 ou 10 semaines d'enseignement (en d'autres termes, vous serez dispensé ou non de la première partie du niveau).

- **Par défaut, l'enseignement dure tout le semestre.** Si vous êtes en « Standard 10 semaines », il n'y a pas de vagues d'enseignement.
- Si vous êtes en « Standard 6 semaines », vous restez dans la même vague qu'au premier semestre.
- A suivre sur le site d'enseignement
 - Rubrique « Résultats » pour connaître votre niveau au semestre 2
 - Rubrique « Calendrier » pour connaître les principales dates du niveau dans lequel vous serez.

ATTENTION !

Pour l'examen (15 points de la note finale), la semaine prochaine, vous devez :

- Avoir **votre carte d'étudiant**
- Connaître **votre mot de passe** pour accéder à **Moodle**

D'ici l'examen :

- Pensez à **terminer les tests de contrôle continu**
(5 points de la note finale)

FORMATS DE FICHIERS

Stage – Semaine 5

FORMATS DE FICHIERS

- Déjà vu : il existe plusieurs formats d'images ?
 - à cause de choix de codage différents
 - Codage matriciel versus codage vectoriel
 - Codage de couleurs (niveaux de gris, modèle RVB, ...)
 - Utilisation ou non d'algorithme de compression (potentiellement destructrice)
- La multitude de formats existe pour d'autres types de documents numériques
 - La raison est toujours des codages différents...
 - ... en suite de 0 et de 1, le bit étant l'information de base pour un ordinateur

CODAGE ?

Codage d'une information :

Règle d'écriture à l'aide d'un nombre fini de symboles permettant de désigner de manière unique l'information

(le codage est contextualisé (codage de nombre, de couleurs, de textes, ...))

Exemple : codage d'entiers

123 \longleftrightarrow Cent vingt trois \longleftrightarrow CXXIII

Trois écritures de la même valeur

à l'aide d'une liste de symboles indécomposables :

- des chiffres (0,1,2, ...)
- des mots (un, deux, dix, cinquante, ...)
- des lettres (I,V,X,L,C, ...)

PRINCIPAUX FORMATS POUR LES TEXTES

Trois niveaux de formats dépendant du type de contenu

- **contenu seulement** (texte brut)
 - Format dit TEXTE : txt
 - Texte formaté par l'utilisateur : html, xml, ...
 - Programmes informatiques : php, c, ...
- **+ les enrichissements** (police, corps, couleurs, ...)
 - Format TEXTE ENRICHI: rtf
- **+ fonctionnalités avancées** (pagination, tables, index, ...)
 - Format de travail de bureautique : doc, docx, odt
 - Format d'échange et de distribution : pdf

LE FORMAT TEXTE SEULEMENT

- La seule information qu'il contient = une suite de caractères
- Conseillé d'utiliser comme logiciel, un « éditeur de texte » (TextWrangler, BBedit, emacs, NotePad++, ...) et non un « logiciel de traitement de texte » (TextEdit, Open Office Writer, Libre Office Writer, Microsoft Word, ...)
- Chaque caractère est codé par (i.e. associé à) une suite de 0 et de 1

A

0	1	0	0	0	0	0	1
---	---	---	---	---	---	---	---

B

0	1	0	0	0	0	1	0
---	---	---	---	---	---	---	---

Exemple :
codage de A et B en
code ASCII ou UTF-8

- ... mais plusieurs tables de codage possibles
 - ASCII
 - Unicode (utf-8, ...)
 - ...
(voir diapositive suivante)

DE L'ASCII À L'UTF-8

- **ASCII d'origine** (aperçu à droite)
 - 7 bits par caractère : caractères latins sans accent.
 - 128 caractères
- ASCII étendu
 - **nombreuses extensions** non compatibles entre elles (une par langue)
 - 8bits par caractère
 - 256 caractères
- « utf-8 » :
 - **une table universelle** (recommandée W3C)
 - Codage variant de 8 à 32 bits pour un caractère ou idéogramme

盲人摸象 - 各執一端

Character	Decimal Number	Binary Number	Character	Decimal Number	Binary Number
blank space	32	0010 0000	^	94	0101 1110
!	33	0010 0001	-	95	0101 1111
"	34	0010 0010	`	96	0110 0000
#	35	0010 0011	a	97	0110 0001
\$	36	0010 0100	b	98	0110 0010
A	65	0100 0001	c	99	0110 0011
B	66	0100 0010	d	100	0110 0100
C	67	0100 0011	e	101	0110 0101
D	68	0100 0100	f	102	0110 0110
E	69	0100 0101	g	103	0110 0111
F	70	0100 0110	h	104	0110 1000
G	71	0100 0111	i	105	0110 1001
H	72	0100 1000	j	106	0110 1010
I	73	0100 1001	k	107	0110 1011
J	74	0100 1010	l	108	0110 1100
K	75	0100 1011	m	109	0110 1101
L	76	0100 1100	n	110	0110 1110
M	77	0100 1101	o	111	0110 1111
N	78	0100 1110	p	112	0111 0000
O	79	0100 1111	q	113	0111 0001
P	80	0101 0000	r	114	0111 0010
Q	81	0101 0001	s	115	0111 0011
R	82	0101 0010	t	116	0111 0100
S	83	0101 0011	u	117	0111 0101
T	84	0101 0100	v	118	0111 0110
U	85	0101 0101	w	119	0111 0111
V	86	0101 0110	x	120	0111 1000
W	87	0101 0111	y	121	0111 1001
X	88	0101 1000	z	122	0111 1010
Y	89	0101 1001	{	123	0111 1011
Z	90	0101 1010		124	0111 1100
[91	0101 1011	}	125	0111 1101
/	92	0101 1100	~	126	0111 1110
]	93	0101 1101			

RECONNAISSANCE DE FORMATS

- **Extension de fichiers** : suffixe de 2 à 4 lettres indiquant le format utilisé pour coder l'information contenue dans le fichier
 - Exemples : txt, odt, docx, pdf, ..., jpg (pour format jpeg), ...
- Le logiciel système associe un logiciel à chaque format (le logiciel associé par défaut peut-être modifié).
- Si le suffixe associé à un fichier est erroné (ne correspond pas au format réellement associé), le logiciel par défaut risque de ne pas savoir ouvrir le document → fichier inutilisable
- Conséquence : conseil =
laisser les logiciels ajouter eux-mêmes les extensions
(Ne saisissez que les noms hors suffixes)
car ils connaissent l'extension adéquate pour le format qu'ils utilisent

TRANSFORMATION DE FORMATS

- Changer (ou saisir) un suffixe ne change pas le format réel du contenu d'un fichier.
- Par contre, les logiciels connaissent généralement :
 - Plusieurs formats
 - Les traitements pour passer de l'un à l'autre (via l'enregistrement ou l'export du fichier... en précisant le « type de fichier » ou le « format de fichier »)
- Ces fonctionnalités d'enregistrement ou d'export sont à utiliser pour changer le format d'un fichier.

INTERNET

Stage – Semaine 5

Est-ce qu'internet = web ?

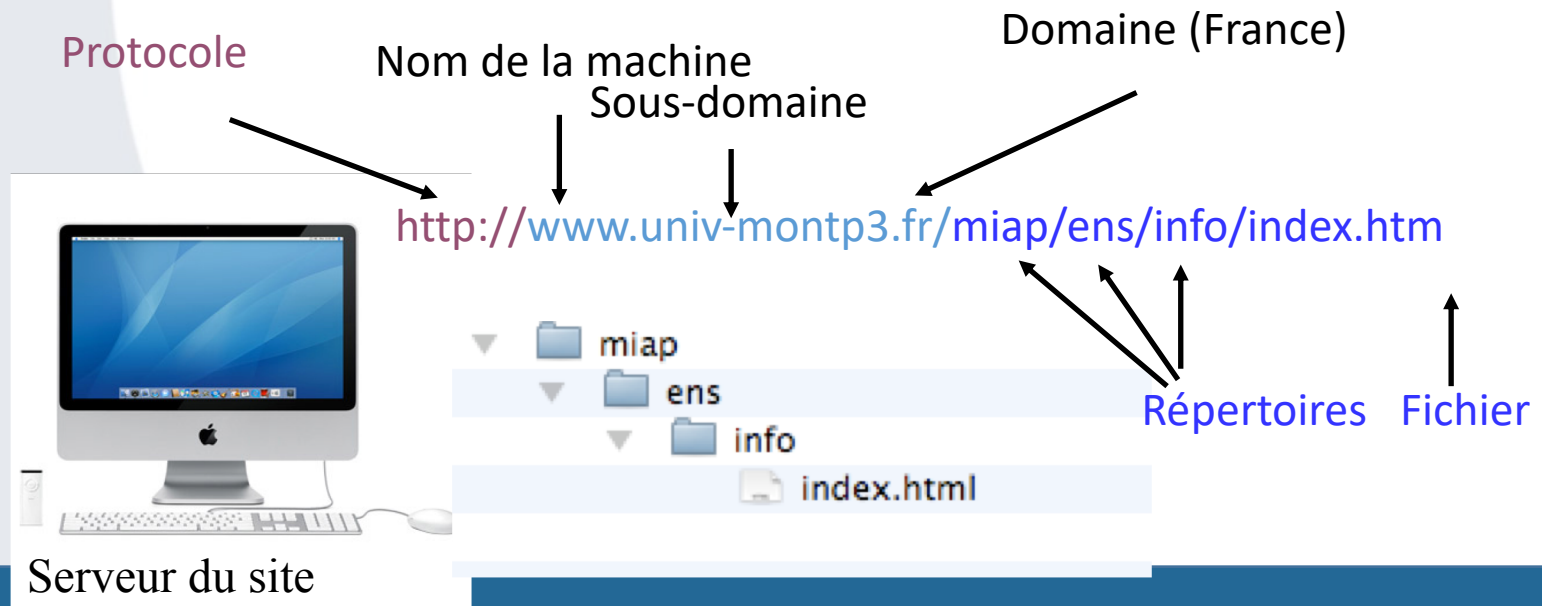
- NON
 - Internet = réseau physique mondial d'ordinateurs (ou plus précisément réseau de réseaux)
 - Internet à 50 ans !
 - Le 29 octobre 1969, transfert de « lo » puis une heure après « login »
 - Voir : https://www.lk.cs.ucla.edu/internet_first_words.html
 - Web (World Wide Web) = réseau d'informations constitués des documents mis à disposition sur les serveurs d'internet et reliés par les hyperliens qu'ils contiennent.
 - Créé au début des années 1990

RAPPELS : CLIENT-SERVEUR

- Principe de base :
 - Un ordinateur (le client) demande un service (exemple : une page web) à un serveur
 - L'échange est effectué en suivant un ou des **protocoles, langages** gérant le dialogue entre machines
- Quelques protocoles :
 - **IP** (Internet Protocol) : gestion d'internet
 - **http** (HyperText Transfert Protocol) : gestion web
 - **https** : idem sécurisé (crypté)
 - **imap** (Interactive Message Access Protocol) : accès à des messageries électroniques à partir de logiciels clients
 - **smtp** (Simple Mail Transfer Protocol) : envoi de mails
 - **ftp** (File Transfert Protocol) : transfert de fichiers (utile quand vous hébergez un site web chez un fournisseur de services)
- Remarque : pare-feu : permet de gérer les protocoles autorisées

ADRESSAGE

- Nécessité de localisation : chaque ordinateur est associée à une adresse l'identifiant gérée par le protocole IP
 - Adresse IP = suite de 32 bits (représentés sous forme de 4 blocs de nombres entre 0 et 255 (8 bits)) en IPv4 ou 128bits en IPv6 en cours de déploiement)
 - Exemples : 193.52.137.213, 10.3.7.12 ...
- Pour le protocole http, localisation d'une page web :



SITE ?

- Un site :
 - Ensemble de pages web dont l'URL débute par un même début, appelé racine du site ou URL du site.
 - Exemples :
 - <http://www.univ-montp3.fr/> : site de l'université
 - <http://www.univ-montp3.fr/miap/ens/info/index.htm> site des enseignements d'informatique

- Lors d'une navigation sur le web, les données échangées avec les serveurs interrogés passent par des serveurs intermédiaires
 - Les données peuvent être lues par d'autres.
 - Vos requêtes peuvent être stockées (obligation légale pendant 1 an des fournisseurs de services – LCEN : Loi pour la confiance dans l'économie numérique)
- Autres traces
 - Cookies (avec RGPD – Règlement général sur la protection des données – vous connaissez !)
 - Historique de navigation
 - Métadonnées dans les fichiers
 - ...

Que se passe-t-il quand on saisit l'adresse IP d'une machine au lieu de l'URL d'un site ?

- Si l'IP correspond à l'adresse d'un site web, l'adresse IP est remplacée par l'URL du site et la page d'accueil du site est affichée (d'autres mécanismes peuvent être mis en place).
- Exemple : 193.52.137.213 ... serveur web de l'université (mais des redirections qui mettent en alerte Firefox)

QUELS OUTILS UTILISEZ-VOUS LORS D'UNE RECHERCHE D'INFORMATION SUR LE WEB ?

1. Un ordinateur (de bureau, portable, smartphone, ...) connecté à internet
2. Un navigateur Web :
 - Chrome, Firefox, Edge, Safari, Opéra, ...



3. Un moteur de recherche :
(site contenant un index
d'une partie du web)



...

ou un méta-moteur de recherche
(site construisant sa réponse
en recoupant les résultats
de requêtes à différents
moteurs de recherche)



DuckDuckGo



...

- Remarque : moteur de recherche \neq navigateur web

EST-CE QU'UN MOTEUR DE RECHERCHE INDEXE TOUT LE WEB ?

- Non
 - Le web est dynamique :
 - Des pages se créent (et disparaissent) régulièrement
 - Les crawlers ou spiders, robots d'indexation, ne peuvent pas tout recenser en temps réel
 - Potentiellement un problème de place dans la base de données d'indexation (et donc des choix sur ce que conserver)
 - Des sites non reliés aux autres (web invisible)
 - Des pages payantes ou privatisées par mot de passe
 - ...

- Un zoom sur des requêtes dans un moteur de recherche
 - But = réduire le nombre de réponses et obtenir des réponses plus précises
- Réflexion sur la qualité des sites consultés :

La qualité des ressources est très variable.
C'est l'internaute qui doit la juger.