

Information, Calcul et Communication

Module 3 : Systèmes

Leçon III.3 : Stockage et transmission de l'information

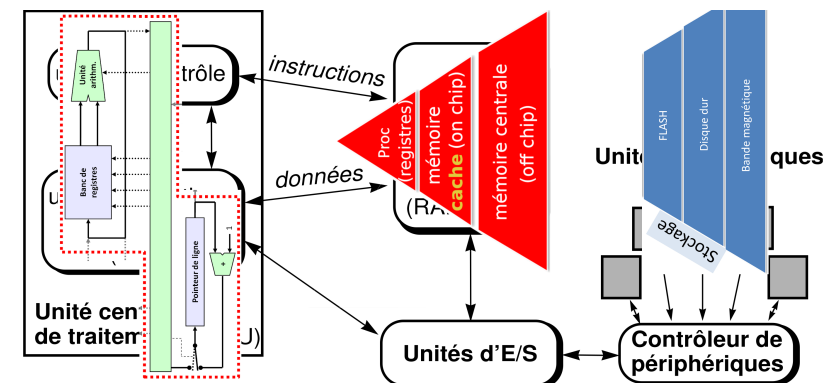
préparée par Prs. Ph. Janson, W. Zwaenepoel
& A. Ailamaki

Objectifs du cours d'aujourd'hui

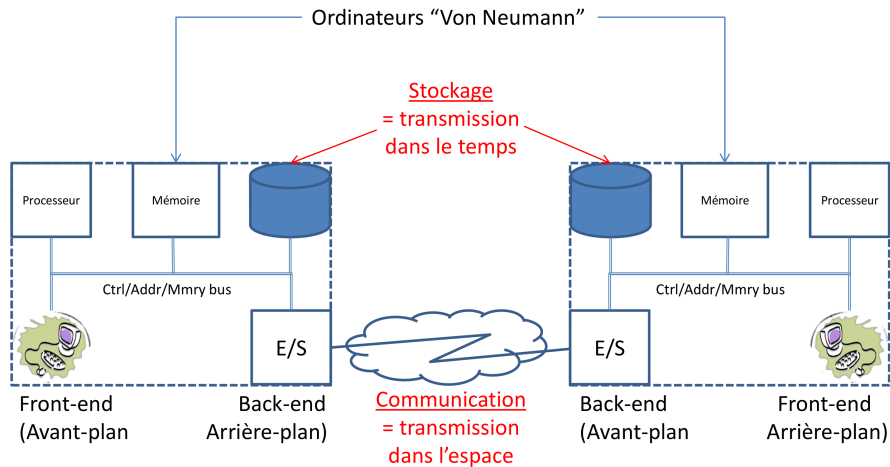
Après avoir vu le cœur de l'architecture des ordinateurs
« de Von Neumann », cette troisième leçon porte sur :

- ▶ la structure des mémoires de masse (mémoires de stockage, mémoires rémanentes)
- ▶ la structure des communications réseau

Architecture de Von Neumann (1955)



Stockage et communication des données



But de cette leçon

Répondre à une seule et même question dans deux cas :

- ▶ Dans le cas du stockage :
Où et comment **stocker** des données de façon à pouvoir les **retrouver plus tard** ?
- ▶ Dans le cas des réseaux :
Quand et comment **envoyer** des données de façon à pouvoir les **recevoir à distance** ?
- ▶ stockage : communication dans le temps au moyen de l'espace
- ▶ télécommunication (réseaux) : communication dans l'espace en utilisant du temps

Plan

- ▶ Le **besoin de structure** dans les données
- ▶ Stockage :
 - ▶ **Types de structures** de stockage : séquentielles, hiérarchiques, relationnelles, ...
 - ▶ **Identification, localisation, et accès** à des données stockées
- ▶ Réseaux :
 - ▶ **Types de structures** de transmission : couches et encapsulation de protocoles
 - ▶ **Identification, localisation, et accès** à des données en réseau


Le stockage : pourquoi ?

Au départ du problème : contraintes technologiques :

- ▶ La mémoire centrale est
 - ▶ Trop petite (quelque Go)
 - ▶ Volatile (tout est perdu quand on éteint)
 - ▶ Trop chère
 - ▶ Le stockage est donc nécessaire
 - ▶ pour retenir *toutes* les données
 - ▶ à long terme
 - ▶ et à coût honorable
- 👉 **Où** et **comment** stocker des données de façon à les **retrouver** ?

Contraintes technologiques

	Latence	Débit	Coût (\$/Go)	Capacité	Rétention	Accès
RAM	1 - 100 ns	Go/s	10	Mo - Go	NON	Aléatoire
Flash	µs	Go/s	0.5	Go - To	Oui	Aléatoire
Disques	ms	100s Mo/s	0.05	> To	Oui	Aléatoire avec délai
Bandes magnétiques	Encore plus lent !	100s Mo/s	Encore moins cher !	Encore plus grand !	Oui	Séquentiel



Le besoin de structure dans le stockage de données

Imaginons un disque (ou autre support) sans aucune structure :



Comment y retrouver une information qu'on cherche ?

- Même la «recherche non structurée» (e.g. moteurs de recherche) a besoin de structure (à elle, qu'elle crée) pour retrouver ce qu'on lui demande !

Le besoin de structure dans la transmission de données

- Imaginons un signal arrivant d'un réseau, sans aucune structure



- Comment savoir si c'est un signal ou juste du bruit ?
- Comment savoir où il commence et où il finit ?
- Comment savoir d'où il vient ?
- Comment interpréter ce qu'il contient ?

Le besoin de structure dans le stockage de données (1/2)

Données non-structurées
(= désordonnées, sans aucun ordre particulier)

- Facile à gérer, stocker, transporter
- Plus difficile à exploiter, explorer, interpréter

Exemple : dans l'océan de données non-structurées qu'un moteur de recherche tente d'indexer sur la toile, retrouver des informations sur le *professeur de Statistiques Michael Jordan* est un défi.



Le besoin de structure dans le stockage de données (2/2)

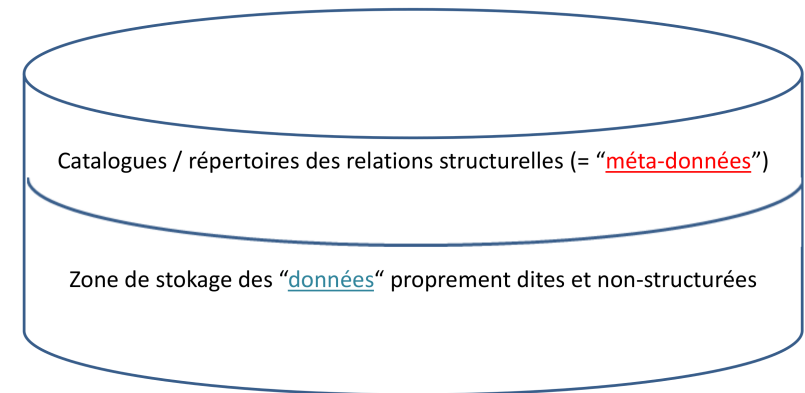
Données structurées
(= ordonnées en listes, piles, hiérarchies, tables, etc.)

- Facile à exploiter, explorer, interpréter...
...si la structure est **adéquate**!
- Plus difficile à gérer, stocker, transporter

Exemple : retrouver des informations sur le *professeur Michael Jordan* dans les bases de données de son université est trivial.



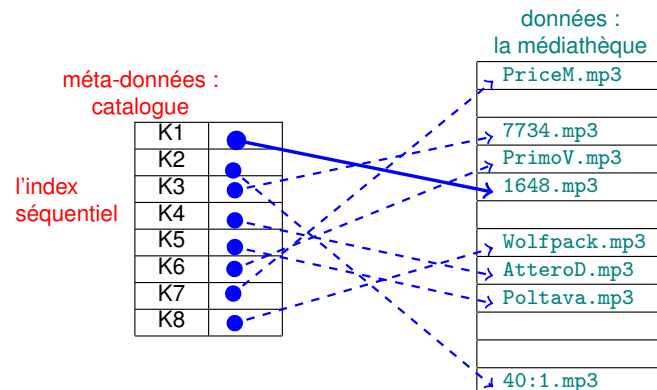
Principe de base de la structuration des données stockées



Le catalogue d'une médiathèque


Catalogue :
indexé (= structuré) par ordre al-
phabétique (par exemple des titres)

Médiathèque :
rangée par ordre d'acquisition
rangée selon la place disponible



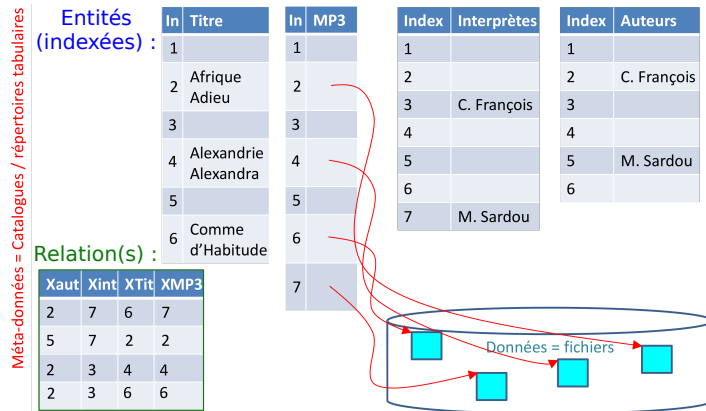
✎ Mais il est difficile de retrouver dans cette médiathèque toutes les œuvres d'un interprète

Une médiathèque hiérarchique



✎ Mais il est difficile de retrouver dans cette médiathèque tous les interprètes d'une œuvre donnée

Une médiathèque relationnelle



Mais (ici) il est moins direct de voir si un auteur est aussi interprète. En fait, il manque l'entité « Personne » et les **relations** Personne–Auteur, Personne–Interprète)

➡ Nécessité de l'**adéquation entre la structure et les besoins**.

Accès à l'information

Le but de toutes ces métadonnées est de permettre l'accès à l'information :

- ▶ l'**identifier** :
 - ▶ comprendre les besoins, les requêtes possibles, ...
 - ▶ l'information elle-même (quelle est elle ? ➡ besoins spécifiques)
- ▶ **retrouver** l'information identifiée :
 - ▶ la **localiser**
 - ▶ y **accéder**

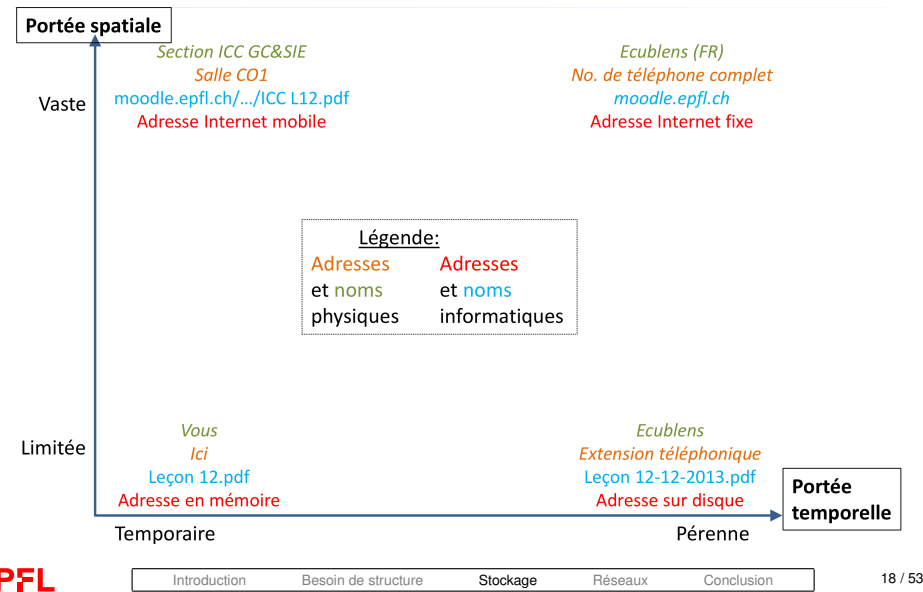
Identification, localisation, et accès à des données stockées

- ▶ Structurée ou non, une information n'a de sens que dans son contexte spatio-temporel
Paris ne signifie pas la même chose à Troie (France) en 2013 qu'à Troie (Turquie) en 1250 avant J.C.
- ▶ Pour **identifier**/distinguer une information parmi d'autres, il faut lui donner un nom/**identificateur**
 Un répertoire/catalogue est alors nécessaire pour **localiser** cette information
- ▶ La localisation de cette information est dénotée par son **adresse** (une place qui lui a été attribuée)
 Un mécanisme d'acheminement est alors nécessaire pour **accéder** à cette adresse
- ▶ Pour accéder à cette adresse il faut déterminer une **route** jusque là

Exemples

Identification	Localisation	Accès
▪ EPFL	▪ Route Cantonale, Ecublens	▪ Plan, carte, GPS
▪ Nom, prénom	▪ No. de téléphone	▪ (Anciennement: no. de tél.) Actuellement route tabulée
▪ No. de compte en banque	▪ No. de compte IBAN	▪ Code BIC / SWIFT
▪ Nom d'utilisateur	▪ Adresse e-mail	▪ Adresse Internet du serveur
▪ Adresse e-mail	▪ Adresse Internet du serveur	▪ Route Internet vers le serveur
▪ Nom d'une variable	▪ Adresse de la variable	▪ Logique d'accès à la mémoire primaire
▪ Nom d'un fichier	▪ Adresse du fichier	▪ Logique d'accès Au stockage sur disque

Portée spatio-temporelle des noms et adresses



Résolution des noms et adresses

Vu le nombre de façons de faire référence à des informations :

- Noms ou adresses
- Universels ou locaux
- Permanents ou temporaires

les ordinateurs doivent régulièrement traduire une forme en une autre.

- C'est un des rôles essentiels des *logiciels systèmes* :
- Les compilateurs traduisent ainsi les noms de variables en adresses mémoire
- Les systèmes de fichiers et les bases de données gèrent le mouvement des données entre mémoire primaire et secondaire y compris la traduction de noms et adresses « secondaires » (universels et permanents) en équivalents « primaires » (locaux et temporaires)

Exemple : compilation de noms de variables en adresses

Identification par nom

- E.g. nom, prénom
- Programme source
delta ← b^2 - 4*a*c

a	@a
b	@b
c	@c
(x)	@x
delta	@delta

Table des symboles du compilateur

Localisation par adresse

- No. de téléphone
 - Programme objet
- charge R,@c
mult R,@a
décale R,2
écris R,@x
charge R,@b
mult R,@b
diff R,@x
écris R,@delta

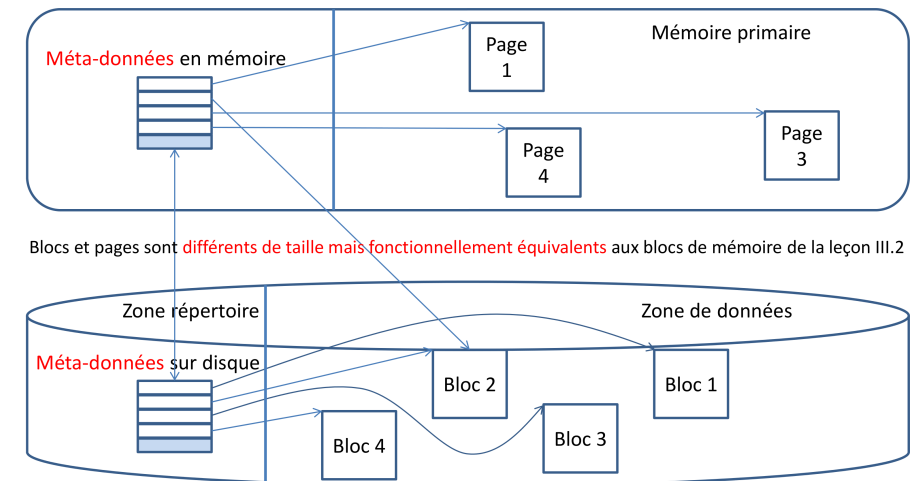
Routage de l'appel
Mémoire primaire

a
b
c
x
delta

Logique d'adressage de la mémoire

Accès

Exemple : gestion de noms et adresses primaires et secondaires



Notion de protocole de communication

Protocole : jeu de règles qui gouverne une communication

Toute communication est gouvernée par un protocole

y compris, la communication entre êtres humains

- ▶ en cours
- ▶ au téléphone
- ▶ ...

Un protocole entre êtres humains peut être vaguement défini (quoique...)

Un protocole entre ordinateurs doit être fixé dans tous les détails

Notion de protocole de communication : exemples

- ▶ Où commence et où finit une communication ?
délimitée par deux silences
- ▶ D'où vient-elle et à qui s'adresse-t-elle ?
de l'orateur au public
- ▶ Dans quel langage est-elle exprimée ?
un langage commun aux interlocuteurs
- ▶ Que faire si la communication est perturbée ?
demande de répétition : « Pardon ? »
- ▶ À qui le tour de communiquer ?
à chacun son tour

Structuration par couches (abstraction des protocoles)

- ☞ Chaque couche gère et abstrait les phénomènes de son niveau pour affranchir les autres couches de ces détails

Exemple d'une conversation téléphonique :



Les couches de l'Internet

5. Application	Terminal interactif ex. SSH	Transfert de fichiers ex. FTP	Courrier électronique SMTP	Naviguer sur la toile HTTP	Le botin Internet DNS	Etc.
4. Transport	TCP		SSL / TLS		UDP	Etc.
3. Réseau	IP (adressage et routage)					
2. Lien	CSMA / CD			PPP	Trunk lines	
1. Physique	Wi-Fi	Ethernet	CATV	ADSL	Trunk lines	

DNS – le bottin de l'Internet, protocole de résolution de noms en adresses

SSH – protocoles de terminaux à distance

FTP, NFS – protocoles de transfert de fichiers


SMTP, POP, IMAP – protocoles de courrier électronique

HTTP – LE protocole de la toile (web, Facebook, Twitter, Google, etc.)

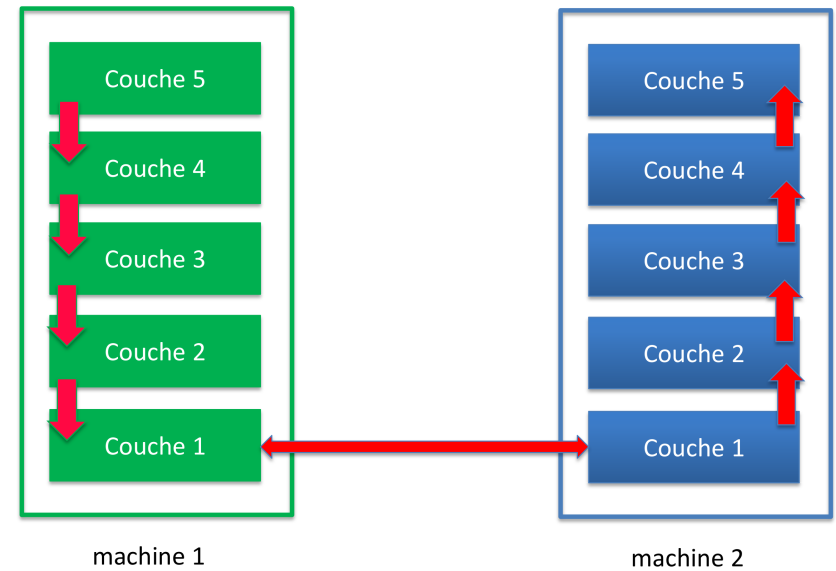
TCP – Transport Control Protocol

IP – Internet Protocol


Couches : communication aux niveaux « logiques »



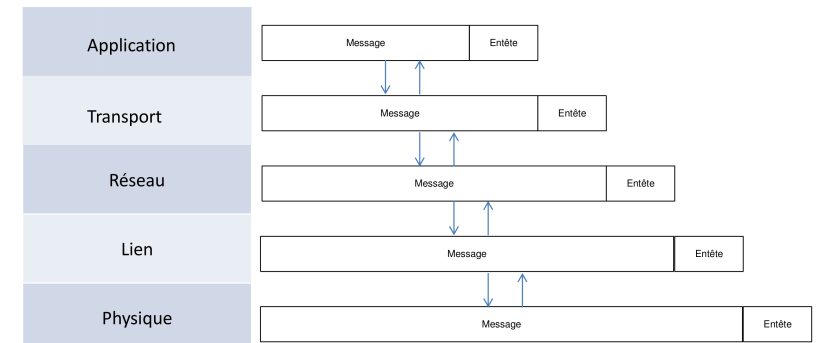
Couches : communication physique simple



Couches : communication physique avec relais



La notion d'encapsulation




Comme on met une lettre dans une enveloppe avant de l'envoyer par la Poste, **chaque couche ajoute** au message de la couche supérieure **un entête** qui lui est propre.

À la réception, chaque couche traite l'entête de son niveau puis le supprimer avant de passer le message à la couche supérieure.

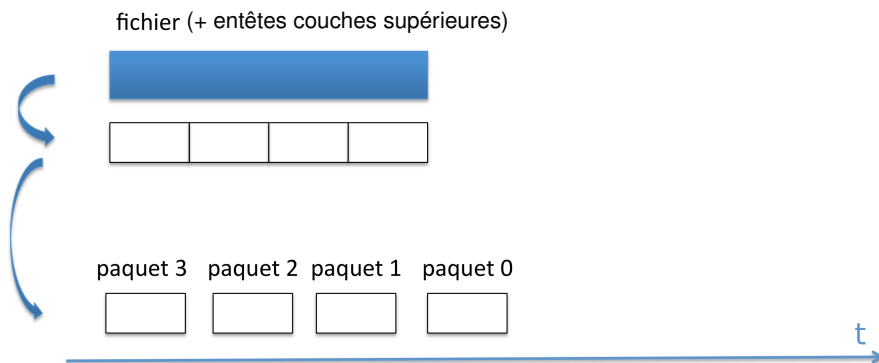
Opérations d'un protocole

- ▶ À la *transmission* d'un paquet : le protocole
 - ▶ reçoit des données
 - ▶ ajoute un entête
 - ▶ envoie le paquet
- ▶ À la *réception* d'un paquet : le protocole
 - ▶ reçoit le paquet
 - ▶ supprime l'entête (en le vérifiant)
 - ▶ passe les données

TCP/IP : Routage Internet par commutation de paquets (couches 3 et 4)



TCP (couche 4) : Envoi d'un fichier par paquets



TCP : et ça fonctionne ?

Note :

- ▶ des paquets peuvent être perdus en route
- ▶ des paquets peuvent arriver en désordre

Fonctionnalités :

- ▶ envoyer des paquets
- ▶ savoir s'ils sont arrivés : le destinataire envoie un **paquet d'acquittement**
- ▶ pouvoir les remettre dans l'ordre (et ne pas traiter 2 fois le même paquet)



Méta-données (entête) TCP

type	seq	données
------	-----	---------

- ▶ type : données ou « paquet d'acquittement »
- ▶ seq : 0,1,2,... identifiant de paquet

Si l'expéditeur ne reçoit pas son paquet d'acquittement au bout d'un certain temps

- ▶ il retransmet
- ▶ un certain nombre de fois puis abandonne

« seq. » permet au récepteur de remettre les paquets dans l'ordre et de savoir si ce sont des retransmissions ou non

« type », « seq. » sont un exemple de **meta-données**

On appelle ces méta-données (y compris d'autres : taille, source, destinataire, code correcteur d'erreurs, ...) l'« *entête* » du paquet

IP (couche 3) : adressage

IPv4 : 32 bits ne peuvent adresser que 2^{32} ($\approx 4 \cdot 10^9$) systèmes écrits a.b.c.d (4 fois 8 bits, en décimal) ; Exemple : **192.168.1.1** interprétés comme R.A
= un abonné A (de 24 à 8 bits) sur un réseau R (de 8 à 24 bits)

IPv6 : 128 bits peuvent adresser $\approx 2 \cdot 10^{38}$ systèmes écrits XXXX:XXXX:XXXX:XXXX:XXXX:XXXX:XXXX:XXXX (8 groupes de 16 bits, en hexadécimal)
Exemple : **2001:db8:0:85a3:0:0:ac1f:8001**

IP : routage (1/2)

Contrairement aux réseaux téléphoniques : **décentralisation totale**, aucune autorité

Les nœuds de commutation n'ont *aucune notion* ni connaissance de connexions

Le routage se fait par « oui-dire », mais résulte en un calcul distribué de « plus courts chemins » :


- ▶ chaque nœud annonce à ses voisins la « longueur » des chemins vers les adresses qu'il connaît
- ▶ chaque nœud retient et propage le chemin le plus court parmi ceux annoncés par ses voisins

(cf transp. suivant)


IP : routage (2/2)

Le routage se fait par un calcul distribué de « plus courts chemins » :

- ▶ chaque nœud annonce à ses voisins la « longueur » des chemins vers les adresses qu'il connaît
- ▶ chaque nœud retient et propage le chemin le plus court parmi ceux annoncés par ses voisins




routing IP : exemple




Exemple de table de routage IP (A)

dest	chemin	distance
B	D	2
C	C	1
D	D	1
E	E	1




Exemple de table de routage IP (D)

dest	chemin	distance
A	A	1
B	B	1
C	A/E	2
E	E	1



Exemple de table de routage IP (C)

dest	chemin	distance
A	A	1
B	A/E	3
D	A/E	2
E	E	1



Tables de routage en pratique

NOTE : en pratique, il est clair que chaque nœud ne stocke pas explicitement toutes les routes vers tous les autres nœuds du réseau. C'est ce que nous ferons dans ce cours pour les petits réseaux utilisés en exemple/exercices, mais en pratique cela serait bien trop grand/coûteux.


En pratique, les « noms » (adresses IP) des nœuds suivent une hiérarchie qui fait que l'on peut :

1. déléguer la gestion des nœuds plus lointains dans la hiérarchie à un nœud particulier de plus haut niveau : la « gateway »
2. décrire de façon plus compacte la route vers des nœuds proches dans la hiérarchie.

Mais cela sort du cadre de ce cours d'introduction.


Routage IP de A à B (1/2)

dest	chemin	distance
B	D	2
C	C	1
D	D	1
E	E	1




Routage IP de A à B (2/2)

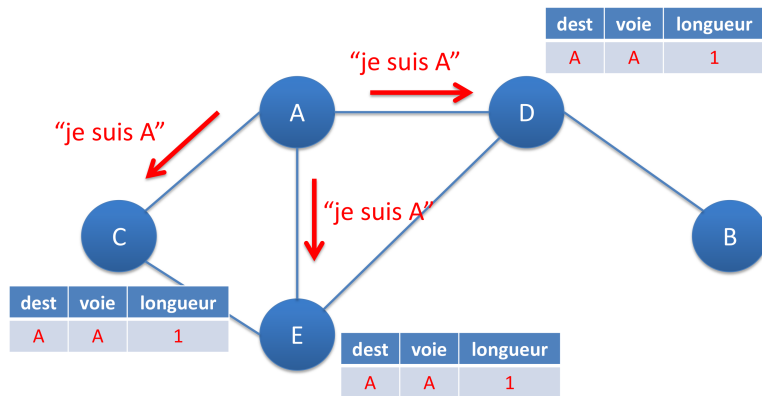
dest	voie	longueur
A	A	1
B	B	1
C	A/E	2
E	E	1



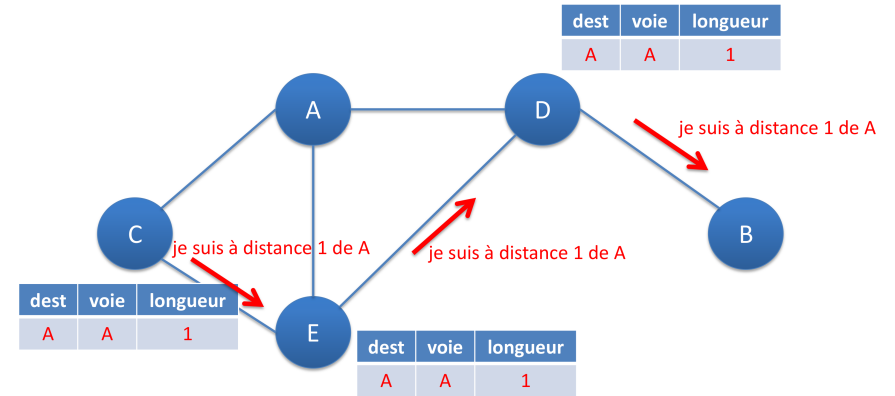
Exemple de calcul de table de routage (1/4)




Exemple de calcul de table de routage (2/4)



Exemple de calcul de table de routage (3/4)



Exemple de calcul de table de routage (4/4)



Couche 4 (transport) : résumé

TCP :


- ▶ protocole de programme à programme (« processus »)
- ▶ flux d'octets fiable :
 - ▶ Adresses des partenaires
 - ▶ Nombre et volume des messages envoyés et reçus
 - ▶ Réordonnancement et réassemblage des messages
 - ▶ Détection d'erreurs et retransmissions

SSL (Secure Session Layer) / TLS (Transport Layer Security) :
une version de TCP *sécurisée cryptographiquement* (prochaine leçon)

Couche 5 : p.ex. DNS (Domain Name System)

DNS traduit les noms en adresses, p.ex. `www.switch.ch` en `13.107.246.61` (adresse IPv4) ou `2620:1ec:bdf::61` (adresse IPv6)

L'assignation de noms est **hiérarchique** mais également totalement **décentralisée**



Couche 5 : p.ex. le Web (HTTP)

HTTP (Hyper-Text Transfer Protocol)

Permet de manipuler des « ressources » au moyen de 8 messages différents dont 4 principaux :

- ▶ POST : crée - ou ajoute une information à - une ressource
- ▶ PUT : crée ou met à jour une ressource
- ▶ GET : lit et renvoie le contenu d'une ressource
- ▶ DELETE : élimine une ressource

Ces ressources sont désignées par des URI (Universal Resource Identifier) et URL (Universal Resource Locator).

`http:// hôte [: port] / [chemin-arborescent [? requête]]`

Le contenu des messages est exprimé en format HTML (Hyper-Text Markup Language)

HTTPS indique l'usage de HTTP sur SSL (Secure Session Layer) / TLS (Transport Layer Security) versions sécurisées cryptographiquement (v. prochaine leçon)

Résumé

- ▶ Architecture « de Von Neumann » est une abstraction : la réalité est bien plus complexe
 - ☞ contraintes technologiques « opposées » (capacité/vitesse)
- ▶ Stockage / Réseaux : 2 facettes (espace / temps) d'un même problème
- ▶ Besoin de structuration de l'information, des données (stockées/transmises)
 - ▶ **stockage** : les données peuvent être organisées logiquement de différentes façons : séquentielle, hiérarchique, relationnelle, ...
Le choix dépend des besoins (quel accès à quelle information ?)
 - ▶ **réseaux** : modèles en couches
- ▶ 3 besoins : identifier, localiser et accéder à (l'information) et 3 moyens : noms, adresses, routes
- ▶ Identifiants : locaux / globaux, temporaires / permanents
- ▶ Un exemple concret : le routage IP (plus court chemin, distribué)

Pour ceux que ça intéresse

Penser en algorithmes



Comment de
simples stratégies
inspirées de l'informatique
peuvent transformer votre vie

Brian Christian et Tom Griffiths

Préface de Martin Vetterli
Président de l'École polytechnique fédérale de Lausanne (EPFL)

Le livre « *Penser en algorithmes* »
(B. Christian & T. Griffiths ; PPUR 2019 ;
trad. de l'anglais « *Algorithms to Live By* »)
présente ce sujet dans son
chapitre 10 : « Les réseaux »