

# Réseaux Datacenter et HPC

## Routage

Elodie Ardoin, Stéphane Mathieu, Damien Gross

11 avril 2018

# Bibliographie

# Plan du cours

## Contexte du cours

Enjeux et problématiques

Configuration type d'un calculateur

## Topologie

Quelques topologies spécifiques

Comparaison des topologies

## Routage

Classification du routage

Eléments d'évaluation de la performance

Quelques algorithmes de routage classiques

# Rappel : Les problématiques réseaux liés au calcul parallèle

- ▶ L'augmentation de la taille des calculs induit une forte augmentation des phases d'échanges de données
- ▶ Pour garantir l'efficacité de la parallélisation, il y est nécessaire de minimiser ces temps de synchronisation :
  - ▶ Garantir la performance du réseau (latence minimale et stable, débit garanti)
  - ▶ Recouvrir des phases d'échange de données par du calcul (asynchronisme des communications)
  - ▶ Optimiser les communications ( RDMA, algorithmique des communications collectives, etc)
- ▶ Pour garantir l'efficience du réseau, il faut aussi minimiser les coûts :
  - ▶ Coût d'aquisition (matériel)
  - ▶ Coût d'opération (résilience, consommation électrique)

## *Rappel : Les choix de design au niveau du réseau d'interconnexion*

- ▶ Les réseaux massifs connectent tous les noeuds du calcul :
  - ▶ La topologie décrit la connexion physique
  - ▶ Le routage décrit la route à emprunter d'une source vers une destination.
  - ▶ Le mode de commutation décrit comment le message est envoyé sur la route.

# Plan du cours

## Contexte du cours

Enjeux et problématiques

Configuration type d'un calculateur

## Topologie

Quelques topologies spécifiques

Comparaison des topologies

## Routage

Classification du routage

Eléments d'évaluation de la performance

Quelques algorithmes de routage classiques

# Plan du cours

## Contexte du cours

Enjeux et problématiques

Configuration type d'un calculateur

## Topologie

Quelques topologies spécifiques

Comparaison des topologies

## Routage

Classification du routage

Eléments d'évaluation de la performance

Quelques algorithmes de routage classiques

# Glossaire du routage

- ▶ **Distance**, longueur du chemin : nombre de *hops* maximum emprunté par la route
- ▶ **Latence** : temps de transport d'un paquet entre une source et une destination ; directement proportionnel à la distance
- ▶ Profil de trafic ou **traffic pattern** : type de trafic porté par le réseau (point à point, permutation, non-uniforme)
- ▶ **Facteur de charge** : nombre de routes porté par un lien
- ▶ **Facteur de contention** : nombre de flux distincts {source-destination} portés par un lien
- ▶ Boucle de routage ou **livelock** : information de routage qui fait toujours passer le même chemin
- ▶ Cul-de-sac ou **deadlock** : information de routage qui conduit à un puits
- ▶ **Résilience** du routage : capacité à recalculer une route en cas de défaut d'un lien, d'un switch
- ▶ Partage de charge ou **load-balancing** : capacité du routage à distribuer la charge (traffic pattern) sur le réseau physique

# Qu'est-ce que le routage ?

- ▶ Le routage est le choix d'un chemin entre une source et une destination, parmi plusieurs.
- ▶ Si la topologie détermine la performance idéale du réseau, le routage est l'un des deux facteurs clés d'atteinte de cette performance.
- ▶ Le routage distribue la charge au sein du réseau.
- ▶ Dans les réseaux IP, on distingue le routage **statique** du routage **dynamique**
- ▶ Dans les réseaux IP, le routage est **distribué**. Chaque routeur est configuré localement et calcule sa table de forwarding.

# Le routage sur les réseaux d'interconnexion de cluster

- ▶ **Garantit la connectivité**, donc ne doit générer ni deadlock ni de livelock
- ▶ **Minimise la latence**, donc la distance pour l'ensemble des routes
- ▶ **Maximise la bande passante** et garantit une bonne répartition de la charge
- ▶ **Est résilient**, donc garantit la connectivité même en cas de défaillance (lien, routeur)
- ▶ Est calculé de manière globale au réseau par un opérateur centralisé : le **subnet manager**
- ▶ Les différentes formes de routage sur les réseaux d'interconnexion sont :
  - ▶ Routage déterministe ou adaptatif ou réparti(*oblivious*)
  - ▶ Routage agnostique ou spécifique à la topologie
  - ▶ Routage minimal ou non-minimal

# Routage déterministe

- ▶ Aussi appelé routage **statique**
- ▶ Les routes sont pré-calculées et ne sont modifiées qu'en cas de modification de la topologie (défaillance du réseau)
- ▶ Deux messages émis par la même source vers la même destination empruntera exactement le même chemin au sein du réseau au cours du temps
- ▶ Inconvénients :
  - ▶ Ces algorithmes ne prennent pas en compte l'état courant du réseau (surcharge, dysfonctionnement, etc.)
  - ▶ La congestion (qui dépend du profil de charge) n'est pas gérée par le routage
- ▶ Avantages
  - ▶ Le calcul du routage est fait a priori. Il n'y a pas de latence induite à chaque saut par une décision de routage.
  - ▶ On a une connaissance précise et constante du routage.

# Routage adaptatif

- ▶ Aussi appelé routage **dynamique** dans les réseaux IP.
- ▶ Les routes principales et optionnelles sont calculées de manière détermiste.
- ▶ Le choix du "next-hop" est fait en fonction de l'état du réseau
- ▶ Les facteurs de considération sont : **disponibilité** et **charge des liens**
- ▶ Le chemin entre une même source et une même destination peut donc changer au cours du temps
- ▶ Inconvénients :
  - ▶ Perte de la connaissance précise des routes (à tout instant)
  - ▶ Difficulté d'estimer la charge globale de la fabrique. La congestion peut être un état transitoire. Remonter l'information de congestion sur toute la fabrique est couteux en temps.
- ▶ Avantages
  - ▶ Meilleure répartition du trafic en cas de charge uniforme
  - ▶ Moins de risque de congestion

## Routage *oblivious*, réparti

- ▶ Les routes principales et les routes optionnelles sont calculées de manière détermiste.
- ▶ Le choix du "next-hop" est choisi de manière **aléatoire** parmi plusieurs routes optionnelles.
- ▶ Ce type de routage s'applique à certains types de messages, insensibles à l'ordre des paquets.
- ▶ Avantages
  - ▶ Meilleure utilisation de la diversité des chemins offerte par la topologie
  - ▶ Meilleure répartition de la charge que le routage déterministe
- ▶ Inconvénients
  - ▶ Désordonne les messages

# Routage en fonction de la destination


- ▶ Chaque paquet possède l'adresse de destination
- ▶ Des coordonnées pour des topologies de type Tor, un identifiant pour les noeuds
- ▶ Le choix de la route dans la table est fonction de l'adresse de destination

# Routage en fonction de la source et de la destination

- ▶ Les informations sont stockées dans l'entête du paquet (ce qui augmente naturellement sa taille)
- ▶ Ces tables sont pré-calculés par le nœud
- ▶ Chaque routeur traversé récupère son information de routage dans le but de l'exploiter

# Empêcher les deadlocks

- ▶ Qu'est-ce qu'un **deadlock** ?
- ▶ Un deadlock est un blocage au sein du réseau parce qu'un message attend la libération d'une ressource (utilisée donc par un autre message) : généralement un buffer ou un virtual channel
- ▶ Exemple simple : une dépendance cyclique



# Empêcher les livelocks

- ▶ Qu'est-ce qu'une boucle de routage ou **livelock** ?
- ▶ Un livelock est un problème similaire aux **deadlocks**, c'est-à-dire qu'un paquet ne peut pas être acheminé correctement jusqu'à sa destination finale. Il continue "d'avancer" dans le réseau sans pour autant atteindre sa destination finale
- ▶ Se produit généralement avec un routage adaptatif
- ▶ Se résout avec un mécanisme de priorité sur les liens

# Routage agnostique et topologique

- ▶ Quels sont les avantages/inconvénients d'un routage agnostique (c'est-à-dire sans prise en compte des propriétés de la topologie) ?
- ▶ Quels sont les avantages/inconvénients d'un routage topologique (c'est-à-dire tirant partie des propriétés de la topologie) ?


# Combinaisons topologie/routage

TABLE II. USABILITY OF TOPOLOGY/ROUTING COMBINATIONS;  
■: DEADLOCK-FREE; ■: ROUTING FAILED; ■: DEADLOCK DETECTED

	Fat-tree	Up*/Down*	DOR	Torus-2QoS	MinHop	SSSP	DFSSSP	LASH
artificial topologies								
2D mesh	r	r	o	o	d	d	o	o
3D mesh	r	r	o	o	d	d	o	o
2D torus	r	r	d	o	d	d	o	o
3D torus	r	r	o	o	d	d	o	o
Kautz	r	r	d	r	d	d	o	o
k-ary n-tree	o	o	o	r	o	o	o	o
XGFT	o	o	o	r	o	o	o	o
Dragonfly	r	r	d	r	d	d	o	o
Random	r	r	o	r	d	d	o	o
real-world HPC systems								
Deimos	r	o	o	r	o	o	o	o
TSUBAME2.0	o	o	o	r	o	o	o	o
topology-aware				topology-agnostic				

FIG.: Source : J. Domke , T. Hoefer, and S. Matsuoka, "Fail-in-place Network Design : Interaction Between Topology, Routing Algorithm and Failures," in Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis, SC '14, (Piscataway, NJ, USA), pp. 597-608, IEEE Press, 2014.

# Quelle résilience ?




Balanced 16-ary 2-tree with 256 HCAs

FIG.: Source : J. Domke, refer to previous slide

# Un peu de réflexion

- ▶ Source : *Principles and practices of Interconnection Networks*, Willian Daly and Brian Towles chez Elsevier
- ▶ Exercice 8.1 p.171

Soit une topologie simple :



An 8-node ring network.

## Soient des algorithmes de routage tel que :


**Greedy:** Always send the packet in the shortest direction around the ring. For example, always route from 0 to 3 in the clockwise direction and from 0 to 5 in the counterclockwise direction. If the distance is the same in both directions, pick a direction randomly.

**Uniform random:** Randomly pick a direction for each packet, with equal probability of picking either direction.

**Weighted random:** Randomly pick a direction for each packet, but weight the short direction with probability  $1 - \Delta/8$  and the long direction with  $\Delta/8$ , where  $\Delta$  is the (minimum) distance between the source and destination.

**Adaptive:** Send the packet in the direction for which the local channel has the lowest *load*. We may approximate load by either measuring the length of the queue serving this channel or recording how many packets it has transmitted over the last  $T$  slots. Note that this decision is applied once at the source because we have disallowed backtracking.

## Soit un motif de communication :



---

Tornado traffic on an 8-node ring network. With greedy routing, all traffic moves in a clockwise direction around the ring, leaving the counterclockwise channels idle.

## Questions :

Quel algorithme choisisiriez-vous pour :

- ▶ minimiser la latence d'un trafic de type Tornado ?
- ▶ maximiser la bande passante d'un trafic de type Tornado ?

*Se limiter au choix d'un seul algorithme pour chaque critère et justifier le choix.*

# Plus de questions

En reprenant l'exercice du *Daly* :

- ▶ quel algorithme minimise la latence d'une communication multiple 1 to 1 ?
- ▶ quel algorithme minimise la latence d'une communication All-to-1 ?

# Analyse


Déductions ?

# Algorithme MinHop

- ▶ Repose sur l'algorithme de Dijkstra qui résout le problème du plus court chemin
- ▶ Chaque arête possède un **poids**
- ▶ On pré-calcule l'ensemble des routes avec pour objectifs de réduire au maximum le poids total de la route
- ▶ Si il existe deux chemins possibles (donc avec le même nombre de sauts), le port le moins assigné est utilisé
- ▶ Routage agnostique, par défaut dans certaines topologies et par certains *Subnet Manager*

# Single-Source Shortest Path

- ▶ Min-hop calculé pour chaque source vers l'ensemble des destinations.
- ▶ Les routes sont distribuées sur les liens par source. Permet une autre distribution des routes



# Layered Shortest Path

- ▶ Idée : virtualiser un lien dans le but d'exploiter plusieurs niveaux
- ▶ Utilisation des *virtual channels* pour créer des plans de routage virtuels
- ▶ Distribution des routes sur ces plans de routage

# Dimension Order

- ▶ Utilisé pour les topologies de type hypercube ou tor
- ▶ Utilisation des coordonnées de la destination pour choisir un chemin
- ▶ Plusieurs chemins possibles suivant le nombre de dimension de la topologie




FIG.: Topologie Tor : 4-ary 2-cube

# Up/Down




FIG.: Up/Down

- ▶ Ne fonctionne que pour des topologies indirectes et hiérarchiques, de type Fat-tree
- ▶ Le choix du next-hop se base sur la charge des liens montants jusqu'au *root switches* commun entre la source et la destination. Puis sur la charge des liens descendants jusqu'aux *leaf switches*.
- ▶ L'intérêt par rapport au Min-hop réside dans la simplicité, et donc à un temps de calcul plus court sur des grandes topologies

## Ftree ou d-mod-k

- ▶ Ne fonctionne que pour des topologies hiérarchiques, de type Fat-tree (PGFT)
- ▶ Rappel sur les topologies PGFT : la bande passante de bisection vaut 1 donc le Fat-tree est *non- bloquant* ; C'est à dire que pour  $N/2$  paires distinctes de noeuds (où  $N$  est le nombre de noeuds), *il existe* un routage non-bloquant.
- ▶ **il existe** signifie qu'il est possible de distribuer les routes sur les liens pour n'avoir qu'une route par lien.
- ▶ *Up/down* distribue la charge à chaque niveau sur les liens de manière aléatoire.
- ▶ Mais quelle distribution choisir ? Quelles sont les communications pour lesquelles il est intéressant d'être non-bloquant ?

# Les motifs de communications

Programmer sur des processeurs à mémoire distribuée nécessite une librairie d'échange de messages = MPI ! Il existe une grande variété de mouvements de données et d'opérations de contrôle des processus, comme :

- ▶ Echange de données **point-à-point**
- ▶ Transposition de matrice = permutation
- ▶ Distribution de l'élément pivot d'une matrice = réplication d'une même donnée entre plusieurs processus
- ▶ Somme de matrice, calcul du min/max d'un vecteur = réduction, contraire de la réplication


# Aparté sur les opérations collectives 1/4

## ► Multiple 1-to-1

- Permutation circulaire : chaque processus envoie un message au processus  $P_{i+1}$ .

### 5.1 Collective Communication Services

209




**Figure 5.1** Two multiple one-to-one communication patterns: (a) circular shift permutation communication and (b) shift communication.

FIG.: Source : Interconnection networks, José Duato, Sudakhar Yalamanchili, Lionel Li

# Aparté sur les opérations collectives 2/4

## ► 1 -to- all

- **Broadcast** : un émetteur envoie un même message à plusieurs récepteurs
- **Scatter** : un émetteur envoie des messages différents à plusieurs récepteurs



**Figure 5.2** Two one-to-all communication patterns: (a) broadcast communication and (b) scatter communication.

**FIG.:** Source : Interconnection networks, José Duato, Sudakhar Yalamanchili, Lionel Li

# Aparté sur les opérations collectives 3/4

## ► all -to- 1

- ▶ **Reduce** : différents messages de différents émetteurs sont combinés via une opération atomique (OR, AND, XOR) pour un récepteur
- ▶ **Gather** : différents messages de différents émetteurs sont concaténés pour un récepteur ; l'ordre de concaténation dépend de l'ID de l'émetteur





Figure 5.3 Two all-to-one communication patterns: (a) reduce communication and (b) gather communication.

FIG.: Source : Interconnection networks, José Duato, Sudakhar Yalamanchili, Lionel Li

# Aparté sur les opérations collectives 4/4

## ► all -to- all

- **All-broadcast** : tous les processus réalisent leur propre broadcast
- **All-scatter** : tous les processus réalisent leur propre scatter



**Figure 5.4** Two all-to-all communication patterns: (a) all-broadcast communication and (b) all-scatter communication.

**FIG.:** Source : Interconnection networks, José Duato, Sudakhar Yalamanchili, Lionel Li

## Ftree ou d-mod-k

L'algorithme Fat-Tree ou D-mod-k distribue les routes de manière à maximiser la bande passante des *permutations circulaires*. C'est à dire les communications entre chaque noeud N et son Xième voisin.

Chaque lien porte les routes vers les destinations d modulo k, où k est le nombre de noeuds connectés sur les switches *leaf*.




FIG.: Source : Evaluation pour les routages haute-performance, Matthieu Perrotin, BULL, 2013

# Routage bloquant




FIG.: Source : Evaluation pour les routages haute-performance, Matthieu Perrotin, BULL, 2013

# Routage non bloquant




FIG.: Source : Evaluation pour les routages haute-performance, Matthieu Perrotin, BULL, 2013

## Pour continuer...

Pour cette topologie PGFT (8 noeuds, 4 leafs, 4 spines) :

- ▶ Terminer le routage au sein de cette fabrique.
- ▶ Que peut-on en déduire quant à la congestion au sein de ce réseau :
  - ▶ Quand chaque noeud communique avec le noeud  $n+3$ (modulo 8) ?
  - ▶ Quand chaque noeud communique avec le noeud  $n-2$ (modulo 8) ?
  - ▶ Quand les noeuds pairs communiquent avec le noeud  $n-2$ (modulo 8) et que les noeuds impairs communiquent avec le noeud  $n+3$ (modulo 8) ?

# Analyse

Déductions ?

Merci de votre attention !

Questions ?