



# Prédiction de Performances pour les Communications Collectives

Luiz Angelo Barchet-Estefanel, Grégory Mounié

► **To cite this version:**

Luiz Angelo Barchet-Estefanel, Grégory Mounié. Prédiction de Performances pour les Communications Collectives. RENPAR'16, 2005, France. pp.101-112, 2005, Organisé par ACM/SIGOPS de France et École de Mines de Nantes. <hal-00004368>

**HAL Id: hal-00004368**

**<https://hal.archives-ouvertes.fr/hal-00004368>**

Submitted on 4 Mar 2005

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Prédiction de Performances pour les Communications Collectives

Luiz Angelo Barchet-Estefanel\*, Grégory Mounié

Équipe MOAIS (CNRS-INPG-INRIA-UJF)  
Laboratoire ID - IMAG  
51, Avenue Jean Kuntzmann  
38330 MONTONNOT SAINT MARTIN, France  
{Luiz-Angelo.Estefanel, Gregory.Mounie}@imag.fr

---

## Résumé

Des travaux récents visent l'optimisation des opérations de communication collective dans les environnements de type grille de calcul. La solution la plus répandue est la séparation des communications internes et externes à chaque grappe, mais cela n'exclut pas le découpage des communications en plusieurs couches, pratique efficace démontrée par Karonis *et al.* [10]. Dans les deux cas, la prédiction des performances est un facteur essentiel, soit pour le réglage fin des paramètres de communication, soit pour le calcul de la distribution et de la hiérarchie des communications. Pour cela, il est très important d'avoir des modèles précis des communications collectives, lesquels seront utilisés pour prédire ces performances. Cet article décrit notre expérience sur la modélisation des opérations de communication collective. Nous présentons des modèles de communication pour différents patrons de communication collective comme « un vers plusieurs », « un vers plusieurs personnalisé » et « plusieurs vers plusieurs ». Pour évaluer la précision des modèles, nous comparons les prédictions obtenues avec les résultats des expérimentations effectuées sur deux environnements réseaux différents, Fast Ethernet et Myrinet.

**Mots-clés :** Communication Collective, Modèles de Communication, Prédiction de Performance, MPI

---

## 1. Introduction

Plusieurs travaux récents visent l'implantation des opérations de communication collective adaptées aux systèmes à grande échelle, notamment les grilles. Dans ces environnements, l'hétérogénéité est un facteur prépondérant qui doit obligatoirement être pris en compte [2]. Cette hétérogénéité représente, néanmoins, un vrai défi pour la prédiction des performances, car les facteurs qui influencent les communications ont des origines très variées, comme la distribution des processus (par exemple, sur une grappe de machines multiprocesseurs), la distance entre les machines et/ou les grappes, le taux d'utilisation du matériel (surtout la congestion du réseau) et la variation de performance du matériel. En effet, très souvent les grilles de calcul combinent différentes machines et réseaux.

L'hétérogénéité inhérente à ces environnements, associée à la volatilité des noeuds dans les grilles de calcul, empêche la création d'opérations spécifiques pour ces environnements, comme en attestent [5] et [28]. Pour simplifier cette modélisation, la plupart des solutions considèrent les grilles comme l'interconnexion d'îlots de grappes homogènes [2]. Dans ce contexte, la majorité des systèmes concentre l'optimisation au niveau des communications entre les grappes, puisque ces liaisons sont généralement plus lentes que celles intérieures à la grappe. Quelques exemples de cette approche en deux couches incluent les bibliothèques ECO [20], MagPle [12][14], et même la bibliothèque LAM-MPI 7 [17], qui considère les machines SMP comme des îlots de communication rapide. Il reste, néanmoins, la nécessité de régler les paramètres de communication pour avoir des performances optimales, et pour cela, la prédiction des performances à travers des modèles de communications est un choix très avantageux.

---

\* Financé par une bourse CAPES - Brésil BEX 1364/00-6

Il existe, toutefois, la possibilité d'organiser les communications en un plus grand nombre de couches. En effet, le travail de Karonis *et al.* [10][11] a démontré que le découpage en plusieurs couches de communication peut conduire à des réductions du temps d'exécution plus importantes qu'un découpage en deux couches, mais pour cela, il est nécessaire la connaissance *a priori* du coût de communication interne à chaque grappe. Dans ce cas, le calcul de la distribution et de la hiérarchie des communications dépend des temps de communication à l'intérieur des grappes, qui varient selon l'opération de communication collective, le nombre de noeuds et les caractéristiques du réseau de chaque grappe.

D'autre part, la prédiction des performances des opérations collectives est aussi intéressante pour d'autres environnements que les grilles. En fait, même si on dispose d'une seule grappe, l'ordre d'exécution des tâches peut influencer largement la performance des systèmes. Dans ces cas, des travaux comme [21] s'intéressent à la prédiction du temps d'exécution d'une tâche, et pour cela, la connaissance des performances de communication représente une étape très importante.

L'approche choisie pour ce travail est la prédiction des performances à partir de la modélisation des opérations de communication collective, par opposition aux prédictions fondées sur des expérimentations réelles (voir Vadhiyar *et al.* [28]). Notre choix s'appuie sur le fait que les prédictions obtenues à partir des modèles de communication ont un coût très réduit par rapport aux expérimentations réelles, sans pour autant perdre en précision. En effet, le travail de Vadhiyar s'oriente maintenant vers la modélisation des performances pour réduire le coût trop élevé des mesures pratiques [29].

Pour illustrer notre approche, ce travail présente des expériences avec les opérations *Broadcast*, *Scatter* et *All-to-All*, lesquelles représentent respectivement les patrons de communications collectives « un vers plusieurs » (*one-to-many*), « un vers plusieurs personnalisé » (*personalised one-to-many*) et « plusieurs vers plusieurs » (*many-to-many*). Conceptuellement simple, les patrons « un vers plusieurs » et « un vers plusieurs personnalisé » sont aussi présents sur d'autres opérations comme *Barriers*, *Reduces* et *Gathers*. En revanche, le patron « plusieurs vers plusieurs » est beaucoup plus complexe parce qu'une opération comme *All-to-All* est sujette à des importants problèmes de congestion réseau.

Cet article présente notre expérience dans la construction de modèles de performance qui caractérisent ces patrons de communication collective très représentatifs. Ces modèles sont utilisés pour prédire la performance des opérations, mais aussi pour choisir la technique d'implantation qui est la mieux adaptée à chaque ensemble de paramètres (nombre de processus, taille des messages, performances du réseau). Pour mieux démontrer l'efficacité de ces modèles, nous avons exécuté des expérimentations sur deux environnements réseau différents, Fast Ethernet et Myrinet.

La suite de cet article est organisée de la façon suivante : la Section 2 présente les définitions qui seront utilisées dans cet article, ainsi que l'environnement de test. Les Sections 3, 4 et 5 présentent respectivement les modèles de communication développés pour les opérations *Broadcast*, *Scatter* et *All-to-All*, et aussi comparent les prédictions des modèles avec les résultats obtenus à partir de nos expériences. Finalement, la Section 6 présente les conclusions et les perspectives futures de notre recherche.

## 2. Modèles et Définitions

Pour créer des modèles précis de communications collectives, il est souhaitable d'avoir un bon modèle de performance pour représenter les communications bipoints. Dans le domaine des applications parallèles avec échange de message, les modèles les plus utilisés sont *BSP* [30] et *LogP* [8]. Même si ces deux modèles sont équivalents dans la plupart des cas, *LogP* est légèrement plus général que *BSP* puisqu'il n'a pas besoin de barrières globales qui séparent les phases de communication et calcul, mais aussi parce que *LogP* contient la notion de réseau de capacité finie, où seulement un certain nombre de messages en transit sont supportés simultanément [24]. Comme conséquence, nous avons choisi pour ce travail le modèle *parameterised LogP* (*pLogP*) [14]. Le modèle *pLogP* est une extension du modèle *LogP* qui peut traiter avec précision les petits comme les grands messages, avec un minimum de complexité. À cause de cette simplicité, ce modèle permet un prototypage rapide des opérations de communication collective, et les modèles développés avec *pLogP* ont permis la prédiction des performances des communications avec une précision suffisante dans la plupart des cas présentés.

Par conséquent, la terminologie employée dans cet article utilise  $g(m)$  pour représenter le coût d'envoi d'un message de taille  $m$  (le *gap*),  $os(m)$  et  $or(m)$  pour représenter respectivement le surcoût dû à l'envoi et à la réception d'un message de taille  $m$ ,  $L$  pour représenter la latence entre deux noeuds, et  $P$  pour

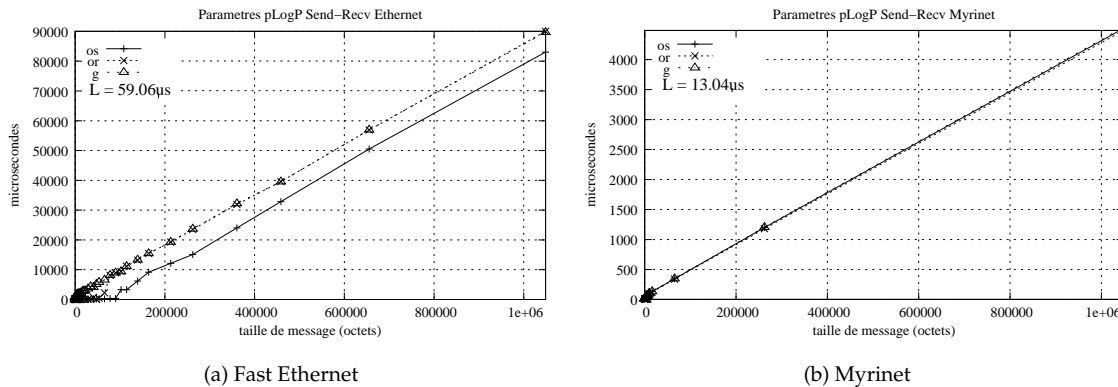


FIG. 1 – Paramètres  $pLogP$  pour le réseau icluster-2

représenter le nombre de noeuds. Dans les cas où il y a segmentation des messages, le segment de taille  $s$  d'un message  $m$  est un multiple de la taille du type basique de données qui est transmis, divisant alors le message initial  $m$  en  $k$  segments. Similairement,  $g(s)$  représente la *gap* d'un segment de taille  $s$ . Ces paramètres furent obtenus avec l'outil MPI LogP Benchmark [13], et sont présentés sur la Figure 1.

Les expérimentations pratiques ont été conduites sur la grappe **icluster-2** au centre de calcul de l'INRIA Rhône-Alpes<sup>2</sup>. Cette grappe contient 104 ordinateurs Itanium-2 (IA-64, biprocesseur, 900MHz, 3GB) interconnectés pour des réseaux Fast Ethernet commuté et Myrinet. Le système d'exploitation est Red Hat Linux Advanced Server 3.0 avec le noyau version 2.4.21smp. Les expérimentations utilisent la bibliothèque LAM-MPI 7.0.4 [17] et consistent en 100 mesures pour chaque ensemble de paramètres (taille du message, numéro de processus), dont la valeur moyenne est considérée dans cet article.

Les prochaines sections détaillent les modèles de communication développés pour les patrons de communication « un vers plusieurs », « un vers plusieurs personnalisé » et « plusieurs vers plusieurs », ainsi que la validation de ces modèles à partir des expérimentations pratiques.

### 3. Un vers Plusieurs : *Broadcast*

Une opération de *Broadcast* s'effectue quand un seul processus, appelé *racine*, envoie le même message de taille  $m$  à tous les autres  $(P - 1)$  processus. Des implantations classiques du *Broadcast* utilisent des arbres qui sont décrits par deux paramètres,  $d$  et  $h$ , où  $d$  est le nombre maximum de successeurs qu'un noeud peut avoir, et  $h$  est la hauteur de cet arbre, le chemin le plus long qui relie la racine et les feuilles de cet arbre. Un arbre optimal peut être construit à partir des paramètres du réseau et avec  $d, h \in [1 \dots P-1]$  tel que  $\sum_{i=0}^h d^i \geq P$  est respecté, mais la plupart des implantations MPI utilisent deux formes fixes, un Arbre Plat pour un nombre réduit de noeuds (jusqu'à 3 noeuds), et un Arbre Binomial pour un plus grand nombre de noeuds.

En plus de ces deux formes d'arbres, différentes techniques sont parfois appliquées pour augmenter leur efficacité. Ces techniques peuvent s'appliquer, pour exemple, à des grands messages, où un message de *rendez-vous* est envoyé pour préparer le récepteur afin de diminuer les copies mémoires. On peut aussi utiliser des primitives de communication non bloquantes pour permettre le recouvrement des communications et du calcul. Malheureusement, ces techniques permettent juste des petites améliorations, et la performance des communications reste néanmoins liée aux caractéristiques du réseau.

Une autre possibilité de construire un *Broadcast* est la composition des chaînes de retransmission [3]. Cette stratégie, utilisée avec la segmentation des messages, présente des avantages importants, comme l'indiquent [14][27][4]. Dans un *Broadcast* à Chaîne Segmentée, la transmission des messages en segments permet le recouvrement de la transmission d'un segment  $k$  et la réception du segment  $k+1$ , minimisant le *gap*.

<sup>2</sup> <http://i-cluster2.inrialpes.fr/>

| Stratégie                   | Modèle de Communication   |
|-----------------------------|---|
| Arbre Plat                  | $(P - 1) \times g(m) + L$   |
| Arbre Plat Rendez-vous      | $(P - 1) \times g(m) + 2 \times g(1) + 3 \times L$  |
| Arbre Plat Segmenté         | $(P - 1) \times (g(s) \times k) + L$  |
| Chaîne                      | $(P - 1) \times (g(m) + L)$   |
| Chaîne Rendez-vous          | $(P - 1) \times (g(m) + 2 \times g(1) + 3 \times L)$  |
| Chaîne Segmentée (Pipeline) | $(P - 1) \times (g(s) + L) + (g(s) \times (k - 1))$   |
| Arbre Binaire               | $\leq \lceil \log_2 P \rceil \times (2 \times g(m) + L)$  |
| Arbre Binomial              | $\lfloor \log_2 P \rfloor \times g(m) + \lceil \log_2 P \rceil \times L$                            |
| Arbre Binomial Rendez-vous  | $\lfloor \log_2 P \rfloor \times g(m) + \lceil \log_2 P \rceil \times (2 \times g(1) + 3 \times L)$ |
| Arbre Binomial Segmenté     | $\lfloor \log_2 P \rfloor \times g(s) \times k + \lceil \log_2 P \rceil \times L$                   |

TAB. 1 – Modèles de communication pour le *Broadcast*

Le choix de la taille des segments reste, néanmoins, dépendant des caractéristiques du réseau. En fait, le coût des segments trop petits est plus dû à l'en-tête qu'à son contenu, et à l'inverse, des segments trop grands ne sont pas capables d'exploiter tout le débit du réseau. La recherche de la taille de segment  $s$  qui minimise le temps de communication peut se faire en utilisant les modèles présentés dans le Tableau 1. D'abord, on cherche une taille de segment  $s$  qui minimise le temps de communication parmi  $s = m/2^i$  pour  $i \in [0 \dots \log_2 m]$ . Ensuite, on peut affiner la recherche de la taille optimale avec des heuristiques comme le « *local hill-climbing* » proposée pour Kielmann *et al.* [14].

Nous avons établi plusieurs modèles pour représenter les stratégies de communication et leurs techniques associées, qui sont présentées sur le Tableau 1. La majorité de ces modèles sont clairement inefficaces, donc nous avons choisi pour cet article les stratégies d'Arbre Binomial et Chaîne Segmentée. Ces stratégies seront analysées en Section 3.1, où seront comparées les prédictions des modèles avec les résultats issus des expérimentations pratiques.

### 3.1. Résultats Pratiques

Pour évaluer la précision des modèles de communication, nous avons obtenu les temps de communication des *Broadcasts* en Arbre Binomial et Chaîne Segmentée à partir des expériences pratiques, et ensuite on les a comparés avec les prédictions des modèles. Les Figures 2 et 3 présentent chaque stratégie comparée avec les prédictions de son modèle.

Les prédictions pour les Arbres Binomiaux (Figure 2) sont très proches des résultats pratiques. Pour la Chaîne Segmentée (Figure 3), malgré les différences entre les résultats réels et les prédictions, nous pouvons toujours observer que les prédictions suivent le comportement des opérations réelles. En effet, deux facteurs peuvent influencer fortement le résultat de la Chaîne Segmentée : d'abord le coût de manipulation des segments de message, et surtout la propagation des retards d'une machine à toute la chaîne. Selon l'importance de ces deux facteurs, les résultats obtenus seront plus ou moins éloignés du modèle de communication.

Finalement, la Figure 4 compare directement les stratégies d'Arbre Binomial et Chaîne Segmentée (et leurs prédictions) pour un groupe de 40 machines. Nous pouvons observer que dans ce cas l'algorithme de Chaîne Segmentée est plus performant pour des grands messages, même si les prédictions sont moins précises que pour les autres modèles.

Dans le cas des petits messages, des retards importants sont observés, spécialement sur Ethernet. Les raisons de ces retards sont détaillées dans plusieurs références, dont un article des développeurs du LAM-MPI [18]. Une enquête plus profonde, menée par Loncaric [19], a indiqué que ces retards sont dus à l'implantation des politiques d'acquittement TCP sur Linux, qui occasionne le retard exceptionnel d'un message à chaque  $n$  messages transmis (dont  $n$  dépend de la version du noyau Linux). Ces retards sont observés même si l'option socket TCP\_NODELAY est activée, et influencent fortement la performance des Chaînes Segmentées à cause des tailles de segments utilisées.

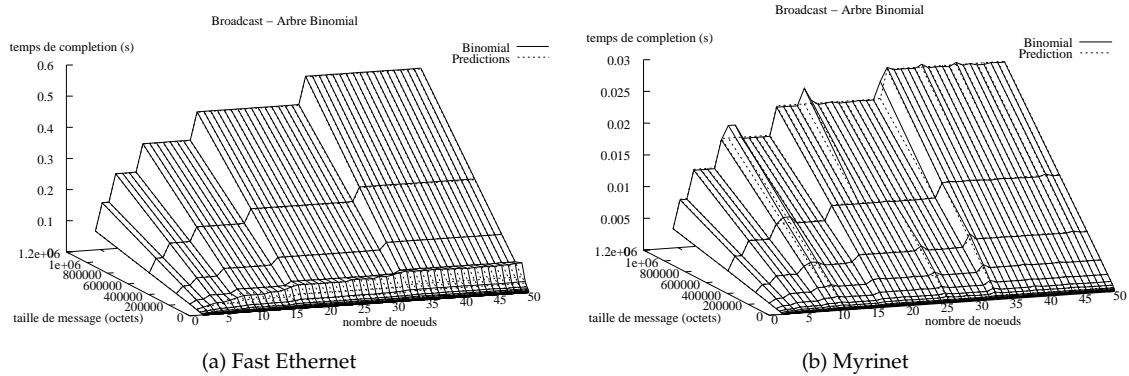


FIG. 2 – Les performances réelles et prédites pour l'Arbre Binomial

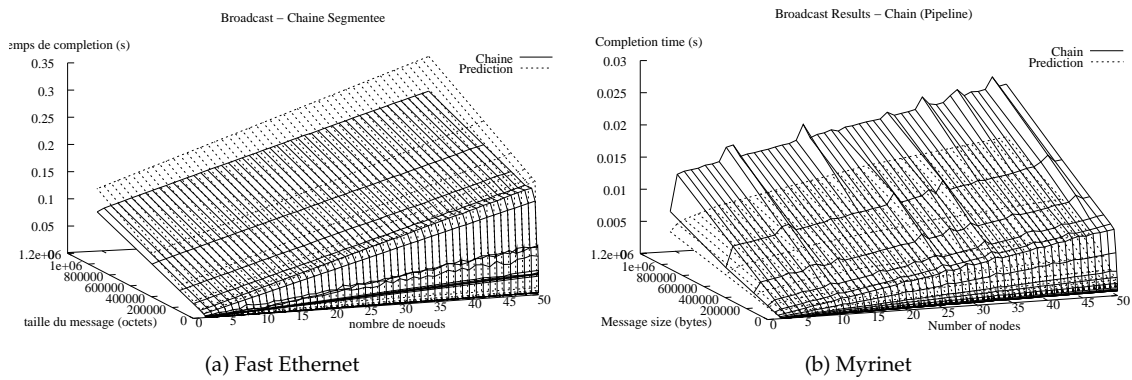


FIG. 3 – Les performances réelles et prédites pour la Chaîne Segmentée

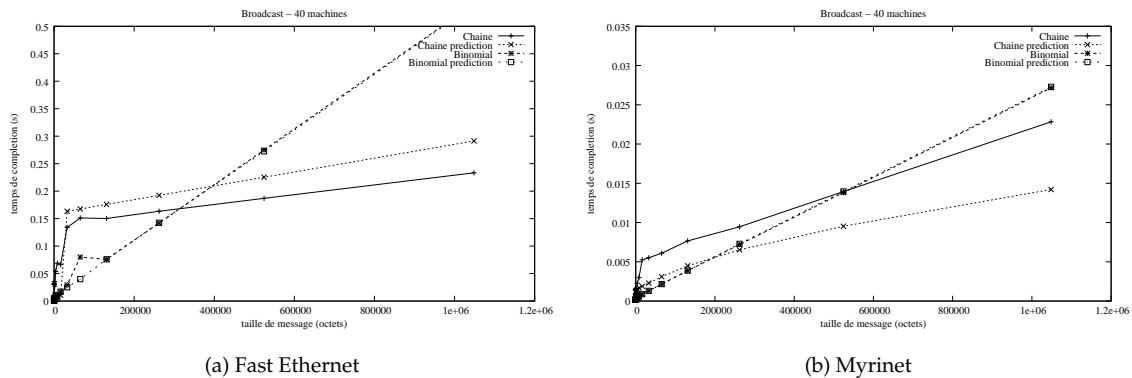


FIG. 4 – Comparaison entre les résultats réels et prédits pour un groupe de 40 machines

| Stratégie      | Modèle de Communication   |
|----------------|---|
| Arbre Plat     | $(P - 1) \times g(m) + L$   |
| Chaîne         | $\sum_{j=1}^{P-1} g(j \times m) + (P - 1) \times L$   |
| Arbre Binomial | $\sum_{j=0}^{\lceil \log_2 P \rceil - 1} g(2^j \times m) + \lceil \log_2 P \rceil \times L$ |

TAB. 2 – Modèles de Communication pour le *Scatter*

#### 4. Un vers Plusieurs Personnalisé : *Scatter*

L'opération *Scatter*, aussi appelée « *broadcast* personnalisé », est une opération où le processus *racine* détient  $P$  messages différents de taille  $m$  qui seront distribués également entre tous les  $P$  processus. Parce que le *Scatter* est l'opération symétrique de l'opération *Gather*, les modèles développés pour le *Scatter* peuvent aussi représenter le patron de communication « plusieurs vers un » de l'opération *Gather*.

Dans le cas du *Scatter*, où la *racine* détient un message différent pour chaque processus, il est généralement considéré que le meilleur algorithme pour les réseaux homogènes utilise les Arbres Plats [14]. Par conséquent, l'implantation en Arbre Plat est l'approche par défaut des bibliothèques MPI.

Ce choix est dû au fait que des alternatives pour les Arbres Plats requièrent toujours que des grands ensembles de messages soient transmis par des noeuds intermédiaires. En prenant par exemple le cas des Arbres Binomiaux, le processus *racine* transmet à ses successeurs des paquets de messages qui contiennent plusieurs messages. Si d'un côté cette stratégie peut bénéficier des envois parallèles, elle a des inconvénients car la transmission des paquets de messages nécessite plus de temps qu'un seul message. Par conséquent, l'efficacité des Arbres Binomiaux dépend surtout de la vitesse de transmission des grands messages, et on observe alors l'effet du compromis entre les envois parallèles et la transmission des grands messages sur le temps total de l'opération.

Le Tableau 2 présente les modèles de communication développés pour le *Scatter*. Pour ce travail, on a choisi de comparer les approches des Arbres Plats et des Arbres Binomiaux, plus performantes. Même si les Arbres Binomiaux ont un surcoût dû à la transmission et manipulation des paquets de messages, la possibilité de faire des envois simultanés doit être évaluée. D'ailleurs, le modèle pour l'Arbre Binomial inclut la relation de compromis entre le coût de transmission et les envois parallèles, ce qui nous donne la possibilité d'évaluer les modèles en fonction des caractéristiques du réseau.

##### 4.1. Résultats Pratiques

Une comparaison entre les résultats pratiques et les prédictions des modèles est présentée dans les Figures 5 et 6. Nous pouvons observer que les prédictions des modèles sont assez proches des résultats pratiques. Les différences observées dans le cas des Arbres Binomiaux sont plutôt dues au coût de manipulation des paquets de messages (extraction, sélection, repaquetage), qui n'est pas représenté par le modèle de performance ( $p \log P$ ).

À cause des caractéristiques de notre réseau, on observe que l'approche des Arbres Binomiaux est fréquemment plus efficace que l'approche des Arbres Plats. Plus exactement, la simplicité du modèle Arbre Plat est supplantée par la capacité de répartir la charge des transmissions entre plusieurs noeuds. Ce résultat s'avère très utile pour l'augmentation des performances de l'opération *Scatter*.

Lorsque le modèle en Arbre Plat est limité par le temps nécessaire à la transmission des messages successifs (le *gap*), sa performance est directement liée au nombre de processus. En revanche, le coût du modèle en Arbre Binomial augmente de façon logarithmique ( $\lceil \log_2 P \rceil$ ), ce qui offre des performances très avantageuses aux communications avec un nombre de noeuds légèrement inférieur à  $2^x$  pour  $x \in \mathbb{N}$ . Néanmoins, la variation des performances du modèle en Arbre Binomial selon le nombre de processus encourage la comparaison préalable des modèles de performance, de manière à choisir l'algorithme qui s'adapte le mieux à chaque ensemble de paramètres (taille de message, nombre de noeuds), comme illustre la Figure 7.

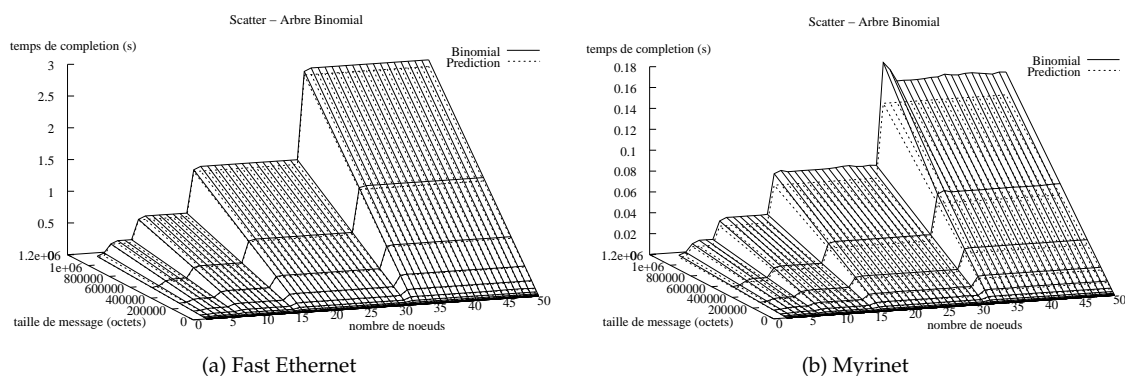


FIG. 5 – Performances réelles et prédites pour le Scatter en Arbre Binomial

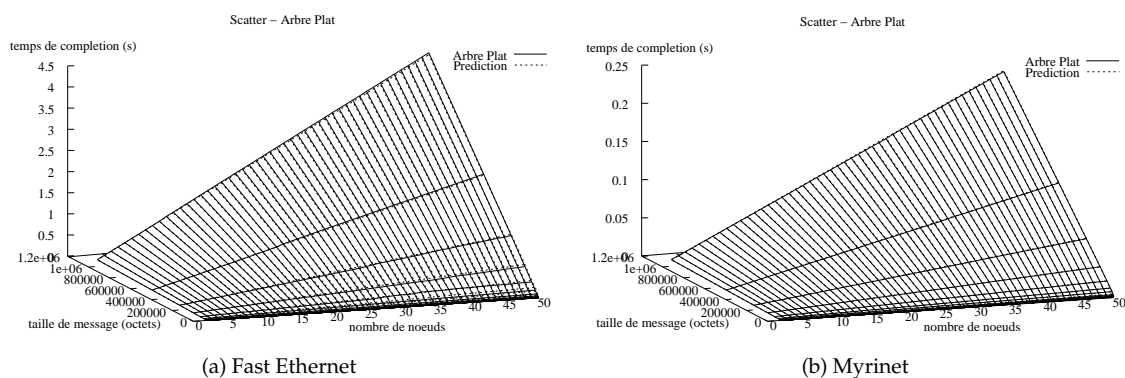


FIG. 6 – Performances réelles et prédites pour le Scatter en Arbre Plat

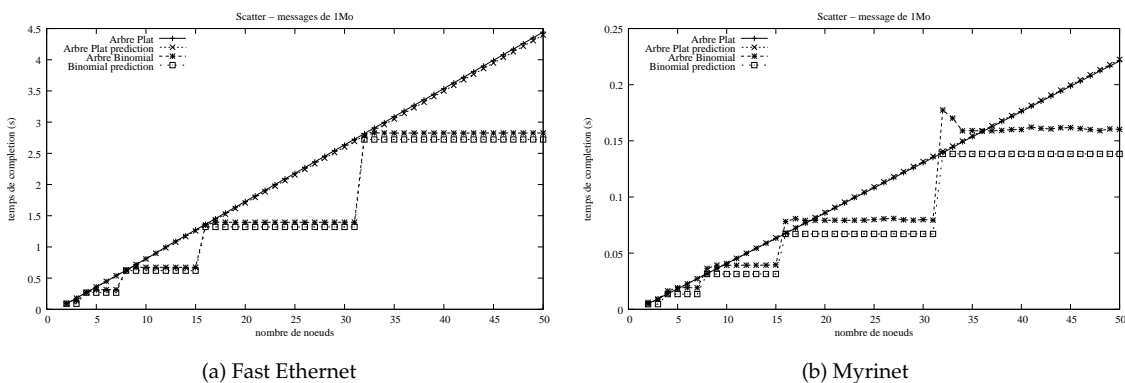


FIG. 7 – Comparaison entre les résultats réels et prédits pour des messages de 1Mo



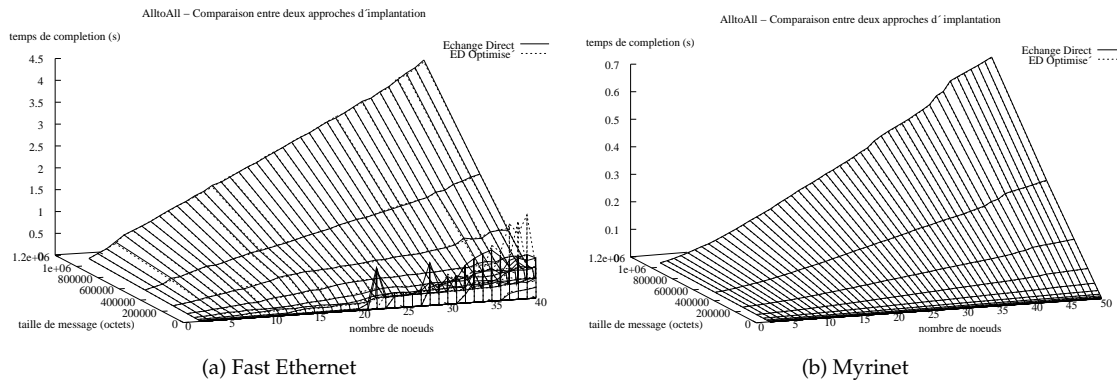


FIG. 8 – Comparaison entre les approches *Échange Direct* et *Échange Direct Optimisé*

### 5. Plusieurs vers Plusieurs : *All to All*

Un des plus importants patrons de communication collective pour des applications scientifiques est l'échange total [6], où les algorithmes parallèles alternent des périodes de calcul avec des périodes d'échange de données entre les processus. Pour cela, une des opérations plus répandues est le *All-to-All*, qui permet la transposition des données appartenant à un groupe de processus. Dans le cas de l'opération *All-to-All*, chaque processus détient  $m \times P$  unités de données qui seront distribuées également entre les  $P$  processus.

Plusieurs travaux visent l'optimisation du *All-to-All* et sa variante *All-to-All-v*, qui permet l'envoi des messages avec des tailles différentes pour chaque processus. Cependant, la plupart des propositions sont adaptées à des structures d'interconnexion très spécifiques, comme dans le cas des topologies en grille, tores et hypercubes [6]. Des solutions générales, comme celles implémentées sur plusieurs distributions MPI, considèrent que chaque processus ouvre une communication directe avec les autres processus.

L'approche la plus simple d'implantation de *All-to-All*, que l'on appellera *Échange Direct*, considère que chaque processus communique directement avec les autres, et que tous les appels d'envois et de réceptions sont initiés simultanément. Un exemple de l'approche *Échange Direct* est l'implantation de *MPI\_Alltoall* de LAM version 6.5.2 [16]. Dû à ses caractéristiques, cet algorithme peut avoir des problèmes de surcharge du récepteur, car les processus suivent le même ordre d'envoi, surchargeant un seul processus récepteur à chaque tour. À cause de cela, une optimisation simple consiste en faire la rotation des listes de destinataires, comme le font déjà les implantations MPI LAM 7.0.4 [17] et MPICH 1.2.5 [23]. Malgré cette optimisation, des tests pratiques n'ont pas démontré une grande influence sur le résultat, comme démontre la Figure 8. Nos expériences suggèrent que la surcharge d'un récepteur est un problème mineur en comparaison avec l'occurrence de la congestion réseau. En fait, l'analyse faite par Grove [9] indiquait déjà que les ralentissements observés sont plutôt dus à des pertes de paquets et leurs timeouts de retransmission TCP/IP causés par la surcharge du réseau.

D'ailleurs, on observe sur la Figure 8(a) des grandes variations de performance pour les messages petits. Ces variations, observées seulement sur le réseau Fast Ethernet, sont probablement dues aux problèmes de retard de petits messages déjà discutés en Section 3.1. Le fait que ces retards sont plus importants que ceux observés dans les cas de l'opération de *Broadcast* reflète simplement le surcoût du patron « plusieurs vers plusieurs ».

Par conséquent, la difficulté des modèles de communication pour le *All-to-All* réside dans la prise en compte des spécificités du patron de communication « plusieurs vers plusieurs ». Des modèles théoriques comme ceux présentés par [6] sont pour la plupart des simples extensions du modèle *Scatter*, et ne tiennent pas compte de l'influence de la congestion réseau, par exemple.

En fait, la plupart des travaux de modélisation de performance utilisent des résultats des communications bipoints pour abstraire la performance des communications collectives. Tam et Wang [26][25] ont démontré, toutefois, que le temps d'exécution des opérations de communication collective, spécialement

le *Gather* et le *All-to-All*, est fortement dominé par la congestion du réseau et par la perte de paquets de messages, ce qui rend très difficile la quantification de ces effets.

Pour sa thèse de doctorat, Grove [9] a élaboré une étude très intéressante à propos de modèles de performance. D'une manière concise, son étude a présenté une vision riche du développement et de l'évolution des modèles de performance. Ainsi, il démontre que seulement ces dernières années la congestion est devenue une préoccupation réelle, et que l'influence de la congestion reste encore un des grands défis des concepteurs de modèles.

Un des premiers modèles qui considère les effets de la congestion des ressources fut présenté par Adve [1]. Ce modèle considérait que le temps total d'exécution était réparti entre quatre composants :

$$T = t_{\text{computation}} + t_{\text{communication}} + t_{\text{resource-contention}} + t_{\text{synchronisation}}$$

Malgré sa simplicité conceptuelle, ce modèle n'est pas trivial à cause de la nature non-déterministe de la congestion, et surtout de la difficulté à déterminer les retards moyens de synchronisation.

Même si la congestion des ressources est difficile à modéliser, Clement et Steed [7] ont introduit un moyen simple pour exprimer la congestion sur des réseaux partagés, comme par exemple l'Ethernet non commuté, qui consiste d'un facteur de congestion  $\gamma$  qui augmente un modèle de communication linéaire T :

$$T = l + \frac{b\gamma}{W}$$

où  $l$  est la latence du lien,  $b$  est la taille du message,  $W$  est le débit du lien et  $\gamma$  représente le nombre de processus. Ce modèle augmente la précision des prédictions avec un coût minimum, mais pour cela il faut encore que tous les processus communiquent simultanément, ce qui n'est pas vrai que pour quelques patrons de communication.

Ce résultat est fortement lié au travail de Labarta, Girona et *al.* [15], qui tente d'approcher le comportement de la congestion réseau au considérer que s'il y a  $m$  messages à transmettre, et seulement  $b$  canaux disponibles, les messages sont sérialisés en  $\lceil \frac{m}{b} \rceil$  vagues de communication.

Certains modèles de performance orientés à la congestion sont apparus récemment. *LoGPC* [22] est une extension du modèle *LogP* qui détermine l'influence de la congestion à travers l'analyse des files d'attente sur un réseau de  $n$  cubes de dimension  $k$  chacun. Cette analyse rend très difficile l'utilisation pratique du modèle. Une autre approche, plus pratique, est celle de Tam [25], qui considère la congestion comme part intégrante de la latence. Par conséquent, ce modèle utilise des valeurs de latence qui varient selon la taille du message. Si cette approche est beaucoup plus simple à implémenter, le surcoût dû à l'obtention des valeurs de latence pour plusieurs tailles de messages devient trop élevé quand on considère des réseaux de longue distance.

Pour ce travail nous adoptons une approche similaire à Clement et Steed [7], où la congestion est suffisamment linéaire pour être modélisée. Notre approche consiste à identifier le comportement de l'opération *All-to-All* par rapport à des performances théoriques établies à partir du modèle de communication *1-port*. Notre hypothèse est que la congestion dépend plutôt des caractéristiques physiques du réseau (cartes, liens, commutateurs, ...), de façon que le rapport entre le résultat pratique et les performances théoriques devient une « signature » de ce réseau. Une fois identifié ce rapport, nous pouvons l'utiliser pour prédire la performance d'autres exécutions effectuées sur le même réseau.

Dans le cas des communications du type *All-to-All*, les valeurs de performance théorique sont obtenues à partir de l'extension du modèle *Scatter*, mais cette fois-ci tenant compte des caractéristiques et restrictions du patron « plusieurs vers plusieurs », en particulier la capacité des noeuds à recouvrir l'envoi et la réception des messages.

En fait, selon le modèle de communication *1-port*, un processus peut envoyer et recevoir des messages simultanément. Cependant, des restrictions dues à la congestion peuvent forcer les machines à sérialiser leurs envois et réceptions. Dans ce cas, en reprenant les notions de *pLogP*, nous étudions le fait que même si deux messages ne peuvent pas être envoyés consécutivement en moins de  $g$  unités de temps à travers le même lien, il suffit de  $os$  unités de temps pour envoyer un message (plus spécifiquement, pour délivrer le message à la carte réseau) et  $or$  pour le recevoir.

Par conséquent, la limite inférieure est représentée par la capacité d'envoyer et recevoir des messages simultanément. Pour la limite supérieure théorique, les noeuds sérialisent leurs envois et réceptions. Il

|                   | Modèle de Communication                           |
|-------------------|---|
| Limite Supérieure | $(P - 1) \times os(m) + (P - 1) \times or(m) + L$ |
| Limite Inférieure | $(P - 1) \times g(m) + L$                         |

TAB. 3 – Limites de communication pour l'opération *All-to-All*




FIG. 9 – Performance de l'algorithme *All-to-All* comparé aux limites théoriques et aux prédictions du modèle, pour 24 machines

est possible que la performance réelle dépasse la limite supérieure, car existent d'autres facteurs qui peuvent influencer les communications. Toutefois, l'observation des limites théoriques permet la séparation des facteurs liés au transit des messages et les facteurs dus au matériel physique, ce qui rend possible la définition de cette « signature » du réseau. Les formules pour les limites théoriques sont présentées sur le Tableau 3.

### 5.1. Résultats Pratiques

Pour illustrer notre approche, nous présentons en Figure 9 les résultats des expériences avec l'algorithme *Échange Direct* et les limites théoriques pour 24 machines. La première observation importante est l'écart entre le résultat réel et la limite inférieure (basé sur le modèle *Scatter*). Cette différence non négligeable est déjà due aux effets de la congestion du réseau.

L'observation de ces valeurs permet l'approximation des résultats réels à travers une relation de congestion établie entre les limites théoriques. Cette relation de congestion  $\gamma$  est constante et dépend uniquement des caractéristiques du réseau, dont les limites inférieures et supérieures (définies dans le Tableau 3) dépendent du nombre de processus. Ainsi, nous proposons pour cette relation la formule suivante :

$$T = LimInférieure + (LimSupérieure - LimInférieure) \times \gamma$$

Des relations de congestion qui permettent une bonne approximation des résultats réels présentés en Figure 9 sont  $\gamma = \frac{1}{5}$  pour le réseau Fast Ethernet et  $\gamma = \frac{3}{2}$  pour le réseau Myrinet. L'application de ce facteur  $\gamma$  sur d'autres expériences où on varie le nombre de processus s'est montrée assez fiable, surtout pour des grands messages. La prédiction de performance pour les petits messages reste encore sujette à des facteurs difficiles à contrôler, comme par exemple les retards dus à la synchronisation des processus, la performance du réseau ou les problèmes liés à l'implantation du protocole TCP. Les prédictions obtenues avec notre modèle de performance sont présentées en Figure 10.

## 6. Conclusions et Travaux Futurs

Des travaux récents visent l'optimisation des opérations de communication collective dans les environnements de type grille de calcul. La solution la plus répandue est la séparation des communications internes et externes à chaque grappe, comme le font les systèmes ECO [20], MagPie [12][14], et LAM-MPI

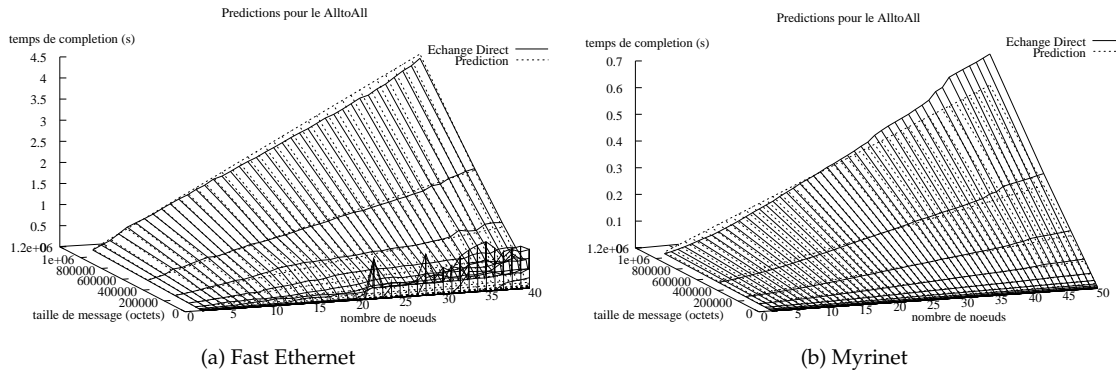


FIG. 10 – Prédications de performance pour l’algorithme *All-to-All*

7 [17], mais cela n’exclut pas le découpage des communications en plusieurs couches, pratique efficace démontrée par Karonis *et al.* [10]. Dans les deux cas, la prédiction des performances est un facteur essentiel, soit pour le réglage fin des paramètres de communication, soit pour le calcul de la distribution et de la hiérarchie des communications. Pour cela, il est très important d’avoir des modèles précis des communications collectives, lesquels seront utilisés pour prédire ces performances.

Cet article présente notre expérience dans le domaine de la modélisation des opérations de communication collective. L’efficacité de ces modèles est analysée à travers la comparaison entre les prédictions de performance et les résultats réels obtenus pour trois importants patrons de communication collective : « un vers plusieurs », « un vers plusieurs personnalisé » et « plusieurs vers plusieurs ». Pour cela, les expériences ont utilisé deux architectures réseaux différentes, Fast Ethernet et Myrinet. Nous démontrons que les modèles de communication sont suffisamment précis pour prédire les performances de ces opérations collectives sur les deux environnements réseaux, et aussi pour permettre la sélection des techniques le plus adaptées à chaque situation.

Une contribution importante de cet article est l’effort de modéliser les opérations de type « plusieurs vers plusieurs ». En général, ces opérations sont sujettes à des retards importants dûs aux effets de la congestion du réseau. Dans notre approche, un facteur de congestion linéaire  $\gamma$ , obtenu à partir des modèles de performance théoriques, est utilisé pour prédire les performances de ce type d’opération collective avec une bonne précision et surtout un coût très bas. Même si notre modèle de communication « plusieurs vers plusieurs » ne couvre pas tous les effets de congestion qui peuvent influencer les résultats réels, en particulier dans le cas des petits messages, il fournit des indices qui contribuent à la recherche des modèles plus précis.

Cet article s’encadre dans le contexte de notre recherche sur des communications collectives adaptées aux environnements de grille. Nous sommes particulièrement intéressés à la construction automatique des communications collectives à multiples niveaux, dont la modélisation des performances, la découverte du réseau et la construction des hiérarchies de communication sont des aspects essentiels.

## Bibliographie

1. V. Adve, “Analysing the Behavior and Performance of Parallel Programs”, PhD Thesis, University of Wisconsin, Computer Sciences Department, 1993.
2. L. A. Barchet-Estefanel, G. Mounié, “Identifying Logical Homogeneous Clusters for Efficient Wide-Area Communication”, in *Proc. of the Euro PVM/MPI 2004*, LNCS Vol. 3241, 2005, pp. 319-326.
3. R. Barnett, D. Payne, R. van de Geijn, J. Watts, “Broadcasting on meshes with wormhole routing”, *Journal of Parallel and Distributed Computing*, 35(2), pp. 111-122, 1996.
4. O. Beaumont, L. Marchal, “Pipelining Broadcasts on Heterogeneous Platforms under the One-Port Model”, Technical Report 2004-32, LIP, ENS Lyon, France, 2004.
5. P. Bhat, C. Raharendra, V. Prasanna, “Efficient Collective Communication in Distributed Heterogeneous Systems”, *Journal of Parallel and Distributed Computing*, vol 63, pp. 251-263, 2003.

6. C. Christara, X. Ding, K. Jackson, "An efficient transposition algorithm for distributed memory computers", in *Proc. High Performance Computing Systems and Applications*, 2000, pp. 349-368.
7. M. Clement, M. Steed, P. Crandall, "Network performance modelling for PM clusters", in *Proceedings of Supercomputing*, 1996.
8. D. Culler, R. Karp, D. Patterson, A. Sahay, E. Santos, K. Schauer, R. Subramoniam, T. von Eicken, "LogP - A practical model of parallel computing". *Comm. of the ACM*, 39(11), pp. 78-85, 1996.
9. D. Grove, "Performance Modelling of Message-Passing Parallel Programs", PhD. Thesis, University of Adelaide, 2003.
10. N. T. Karonis, B. Supinski, I. Foster, W. Gropp, W. Lusk, J. Bresnahan, "Exploiting Hierarchy in Parallel Computer Networks to Optimize Collective Operation Performance", in *14th International Conference on Parallel and Distributed Processing Symposium*. IEEE Computer Society, 2000, pp. 377-384.
11. N. T. Karonis, I. Foster, B. Supinski, W. Gropp, E. Lusk, and S. Lacour, "A Multilevel Approach to Topology-Aware Collective Operations in Computational Grids", Technical report ANL/MCS-P948-0402, Mathematics and Computer Science Division, Argonne National Laboratory, 2002.
12. T. Kielmann, R. Hofman, H. Bal, A. Plaat, R. Bhoedjang, "MagPle : MPI's Collective Communication Operations for Clustered Wide Area Systems", in *Proc. ACM Symposium on Principles and Practice of Parallel Programming*, 1999, pp. 131-140.
13. T. Kielmann, H. Bal, K. Verstoep, "Fast Measurement of LogP Parameters for Message Passing Platforms", in *4th Workshop on Runtime Systems for Parallel Programming*, LNCS Vol. 1800, 2000, pp. 1176-1183.
14. T. Kielmann, H. Bal, S. Gorlatch, K. Verstoep, R. Hofman, "Network Performance-aware Collective Communication for Clustered Wide Area Systems". *Parallel Computing*, 27(11), pp. 1431-1456, 2001.
15. J. Labarta, S. Girona, V. Pillet, T. Cortes, L. Gregoris, "DiP : A parallel program development environment", in *Proc. of the 2<sup>nd</sup> Euro-Par Conference*, vol II, 1996, pp. 665-674.
16. LAM-MPI Team. LAM/MPI Version 6.5.2. <http://www.lam-mpi.org/>, 2003.
17. LAM-MPI Team. LAM/MPI Version 7. <http://www.lam-mpi.org/>, 2004.
18. LAM-MPI Team, "Performance Issues with LAM/MPI on Linux 2.2.x", <http://www.lam-mpi.org/linux/>, 2001.
19. J. Loncaric, "Linux TCP patches to improve acknowledgement policy", <http://research.nianet.org/~josip/LinuxTCP-patches.html>, 2000.
20. B. Lowekamp, "Discovery and Application of Network Information", PhD Thesis, Carnegie Mellon University, 2000.
21. E. T. Midorikawa, H. M. Oliveira, J. M. Laine, "PEMPIs : A New Metodology for Modeling and Prediction of MPI Programs Performance", in *Proc. of the SBAC-PAD 2004*, IEEE Computer Society, 2004, pp. 254-261.
22. C. A. Moritz, M. I. Frank, "LoGPC : Modeling Network Contention in Message-Passing Programs", *IEEE Trans. Parallel and Distributed Systems*, 12(4), pp. 404-415, 2001.
23. MPICH Team. MPICH Version 1.2.5. <http://www-unix.mcs.anl.gov/mpi/mpich/>, 2003.
24. D. Skillicorn, J. Hill, W. McColl, "Questions and answers about BSP". *Scientific Programming*, 6(3), pp. 249-274, 1997.
25. A. Tat Chun Tam, "Performance Studies of High-Speed Communication on Commodity Cluster", PhD Thesis, University of Hong Kong, 2001.
26. A. Tat Chun Tam, C. Wang, "Realistic communication model for parallel computing on cluster", in : *Proc. of the International Workshop on Cluster Computing*, 1999, pp. 92-101.
27. R. Thakur, W. Gropp, "Improving the Performance of Collective Operations in MPICH", in *Proc. of the Euro PVM/MPI 2003*, LNCS Vol. 2840, 2003, pp. 257-267.
28. S. Vadhiyar, G. Fagg, J. Dongarra, "Automatically Tuned Collective Communications", in *Proc. of Supercomputing 2000*, 2000.
29. S. Vadhiyar, G. Fagg, J. Dongarra, "Towards an Accurate Model for Collective Communications", *International Journal of High Performance Computing Applications*, 8(1), pp. 159-167, 2004.
30. L. G. Valiant, "A bridging model for parallel computation". *Communications of the ACM*, 33(8), pp. 103-111, 1990.