

Performance Evaluation of Parallel Programs on an Experimental GRID Computer

Ioan Ungurean, Ștefan Gheorghe Pentiuc, and Vasile Găitan

Abstract—In this paper there will be a discussion about parallel programs performance. These programs were developed using the OpenMPI implementation of the Message Passing Interface (MPI) standard and are being run on an experimental grid computer made of 7 desktop computers. These test applications measure execution times for applications implementing the Jacobi approximation for a linear system of equations. The output of the test application is the processing speed, measured in MFlops and obtained using more methods in order to test more aspects of inter-process communication. The final purpose of this paper is to see increasing performance in a Grid by increasing the number of computing nodes.

Index Terms—grid computing, Globus Toolkit, Message Passing Interface, OpenMPI, parallel computing

I. INTRODUCERE

ÎN această lucrare ne propunem testarea performanțelor programelor paralele [1][2]. Aceste programe sunt realizate folosind implementarea OpenMPI [3][4] a standardului Message Passing Interface (MPI) [5] și sunt rulate pe un grid experimental format din șapte calculatoare desktop. Aplicațiile măsoară timpul de execuție a aplicațiilor care implementează iterațiile Jacobi [6] pentru aproximarea soluției unui sistem liniar de ecuații. Aplicațiile au ca ieșire viteza de procesare calculată în MFlops și sunt realizate în mai multe variante pentru a testa toate mecanismele de comunicație între procese. Scopul acestei lucrări este urmărirea creșterii performanței de procesare a unui grid [7] prin mărirea numărului de noduri. Lucrarea a fost elaborată în urma studierii conceptelor de grid computing [7] și programare paralelă [8]. Un GRID reprezintă o infrastructură hardware și software care oferă acces consistent la capacitățile de calcul. De fapt ideea principală a GRID-ului o reprezintă dezvoltarea unui sistem în care accesul la resursele de calcul să fie la fel de facil ca și accesul la resursele de electricitate. Unul din lucrurile remarcabile la infrastructura

electrică este faptul că nu presupune cunoașterea locației generatorului de energie electrică și a detaliilor privind

infrastructura rețelei electrice. Din păcate acest deziderat încă nu este îndeplinit în totalitate. Arhitectura unui GRID este structurată pe mai multe nivele, fiecare nivel având câte o funcție specifică. În general nivelul cel mai înalt este focalizat spre utilizator. În cadrul acestei lucrări a fost realizată testarea performanțelor programelor paralele pe un grid experimental. Grid-ul experimental este realizat din calculatoare legate între ele folosind o rețea ethernet de 100Mbit și o rețea ethernet de 1Gbit. Ca pachet software se folosește Globus Toolkit, iar pentru dezvoltarea aplicațiilor paralele pe GRID este instalată o implementarea (OpenMPI) a standardului MPI (Message Passing Interface).

II. LEGEA LUI AMDALH ȘI LEGEA LUI GUSTAFSON

Teoretic, viteza obținută prin paralelizare ar trebui să fie liniară – prin dublarea numărului de procesare ar trebui ca timpul de execuție să se înjumătățească, iar prin dublarea din nou a numărului de procesoare ar trebui ca timpul de execuție să se înjumătățească din nou. În realitate foarte puțini algoritmi pot obține această viteză ideală. Cei mai mulți algoritmi au o evoluție liniară a vitezei de procesare pentru un număr mic de procesoare, care se nivelează într-o constantă pentru un număr mare de procesoare.

Viteza de execuție pe o platforma de execuție paralelă a unui algoritm este dată de legea lui Amdahl [9], lege care a fost formulată de Gene Amdahl în anii 1960. Această lege spune că o parte mică a programului care nu poate fi paralelizată va limita creșterea vitezei de execuție prin paralelizare. Orice problemă matematică sau inginerască de dimensiunii mari va fi formată din părți care pot fi paralelizate și părți care nu pot fi paralelizate (părți secvențiale) [9]. Această relație este dată de ecuația:

$$S = \frac{1}{1 - P} \quad (1)$$

unde S este creșterea vitezei de execuție a programului (ca un factor al vitezei de execuție a programului secvențial original) și P este fracția care este paralelizată. Dacă partea secvențială a programului reprezintă 10% din timpul de execuție, nu se poate obține o creștere a vitezei mai mare de 10 ori, indiferent

Ioan Ungurean – SC PROING SRL Suceava, bd. G. Enescu nr. 38, RO-720253 (e-mail: ioanu32@yahoo.com)

Ștefan Gheorghe Pentiuc – Universitatea Ștefan Cel Mare Suceava, str. Universității nr.13, RO-720229 Suceava (e-mail: pentiuc@eed.usv.ro)

Găitan Vasile – Universitatea Ștefan Cel Mare Suceava, str. Universității nr.13, RO-720229 Suceava (e-mail: gaitan@eed.usv.ro)

de numărul de procesoare care sunt adăugate.




Fig. 1 Reprezentarea grafică a legii lui Amdahl

În Fig. 1 curba formată din punctele albastre ilustrează curba (liniară) care trebuie urmată de creșterea vitezei de execuție în cazul ideal, iar punctele de culoare roz indică curba (ne-optimală) care este urmată în prezent de creșterea vitezei de execuție. Curba formată de punctele galbene reprezintă evoluția timpului de execuție în cazul ideal (ca o asimptotă care se apropie de zero), în timp ce curba formată

de punctele roșii indică timpul de execuție actual (ca o asimptotă care se apropie de o valoare mai mare de zero).

Legea lui Gustafson [9] este o altă lege din știința calculatoarelor foarte apropiată de legea lui Amdahl. Ea poate fi formulată astfel:

$$S(P) = P - a(P - 1) \quad (2)$$

unde P reprezintă numărul de procesoare, S este creșterea vitezei de execuție și partea ne-paralizabilă din procese [2]. Legea lui Amdahl presupune problema fixă și faptul că mărimea secțiunii secvențiale este independentă de numărul de procesoare, în timp ce legea lui Gustafson nu realizează această presupunere [9].

III. ARHITECTURA GRID-ULUI EXPERIMENTAL

Grid-ul experimental este format din 7 calculatoare, din care unul reprezintă serverul iar celelalte 6 reprezintă nodurile de calcul. Pe fiecare calculator este instalat ca sistem de operare Scientific Linux 5.0 și pachetele Globus Toolkit [10] și OpenMPI (reprezintă o implementare open-source a standardului MPI).




Fig. 2 Arhitectura grid-ului experimental.

În plus pe server mai este instalat și un server de gestiune al bazelor de date ProgresSQL. Acest server este cerut de Globus Toolkit pentru a salva în baza de date toate operațiile pe care efectuează pachetul de unelte Globus.

În Fig. 2 este prezentată arhitectura GRID-ului experimental. GRID-ul conține 2 switch-uri (unul de 100Mbps și unul de 1Gbps). La aceste două switch-uri sunt conectate toate nodurile GRID-ului. În acest mod se formează 2 rețele, una se poate folosi pentru administrare și una pentru execuția programelor MPI. Fiecare nod are 2 host-uri (de exemplu pc101 și gpc101) care corespund celor două rețele. Nodurile folosesc clase de IP-uri private iar serverul are IP real și are hostname-ul grid203.eed.usv.ro.

Configurația hardware a calculatoarelor folosite pentru realizarea GRID-ului experimental este următoarea:

- § Procesor: AMD Athlon(tm) XP 2000+ , 1.66 Ghz;
- § RAM: 256MB din care 64MB este folosit de placa video integrată.

IV. MODUL DE MĂSURARE A TIMPULUI ÎNTR-O APLICAȚIE MPI

Pentru a se putea măsura timpul de execuție într-o aplicație MPI se folosește funcția MPI_Wtime. Această funcție returnează o valoare double, valoare care reprezintă timpul trecut de la un moment arbitrar din trecut. Dacă atributul MPI_WTIME_IS_GLOBAL este setat cu valoarea true atunci valoarea returnată de această funcție este sincronizată pentru toate procesele din MPI_COMM_WORLD.

Pentru a se evidenția (și testa) modul de funcționare a acestei funcții s-a realizat o aplicație MPI care măsoară performanța funcției memcpy pe un nod. Aplicația generează un tabel cu 3 coloane: prima coloană reprezintă numărul de octeți transferați, a doua coloană reprezintă timpul măsurat iar a treia coloană reprezintă rata de transfer (exprimată în MegaBytes pe secundă). Timpul este măsurat prin apelarea funcției MPI_Wtime înainte și după apelarea funcției memcpy și efectuarea diferenței dintre cele 2 valori. În continuare este prezentat rezultatul afișat de această aplicație pe un nod. Trebuie remarcat că în cazul în care aplicația creează mai multe taskuri pe același nod performanțele care sunt afișate de fiecare task nu scad în mod semnificativ față de cazul în care aplicația creează un singur task. În continuare este prezentată ieșirea afișată de aplicația de test.

```
[bacon@pc101 memtest]$ mpirun -np 1 memcpy
Lungime (octeti) Timp (sec) Viteza (MB/sec)
4 0.000000 221.985293
8 0.000000 380.609866
16 0.000000 578.969406
32 0.000000 795.288467
64 0.000000 968.785700
128 0.000000 829.865592
256 0.000000 856.236139
512 0.000000 1204.846616
```

1024	0.000001	1225.320201
2048	0.000002	885.592730
4096	0.000005	885.004637
8192	0.000009	881.882907
16384	0.000018	885.801841
32768	0.000041	804.272242
65536	0.000106	620.305692
131072	0.000454	288.719231
262144	0.001643	159.560309
524288	0.003593	145.918895
1048576	0.007304	143.561747
2097152	0.014419	145.443659

V. DETERMINAREA VITEZEI DE PROCESARE

În această secțiune se dorește determinarea vitezei de procesare prin implementarea iterațiilor *Jacobi*[6] pentru aproximarea soluției unui sistem liniar de ecuații. Se va rezolva ecuația Laplace în două dimensiuni cu diferență finită.

Orice analiză numerică va demonstra că iterațiile:

```
while (not converged) {
  for (i,j)
    xnew[i][j] = (x[i+1][j] + x[i-1][j] + x[i][j+1] +
x[i][j-1])/4;
  for (i,j)
    x[i][j] = xnew[i][j];
}
```

vor realiza o aproximație pentru soluția ecuației Laplace. Există un ultim detaliu: înlocuirea valorii xnew cu media valorilor din jurul lui este aplicată doar pentru valorile din interior, valorile de la margine sunt lăsate nemodificate. În practică acest lucru înseamnă că dacă grila are dimensiunile $n \times n$, atunci valorile:

```
x[0][j]
x[n-1][j]
x[i][0]
x[i][n-1]
```

rămân nemodificate. Deoarece valorile sunt înlocuite cu media valorilor din jurul lui această tehnică este denumită și metoda relaxată.

Se va dori calcularea acestei aproximări în paralel. Pentru condiția de terminare a calcului de aproximare (variabila booleană converged din iterația prezentată) se va calcula mai întâi valoarea diffnorm folosind următoarea secvență de cod:

```
diffnorm = 0;
for (i,j)
  diffnorm += (xnew[i][j] - x[i][j]) * (xnew[i][j] -
```

```
x[i][j]);
diffnorm = sqrt(diffnorm);
```

Se va stabili o valoare de referință (de exemplu $10e-2$) iar în momentul în care valoarea `diffnorm` este mai mică decât valoarea de referință se poate spune că aproximarea s-a încheiat (`converged = true`).

Pentru simplitate vom considera un exemplu cu o grilă de 12×12 pe 4 procesoare.




Fig. 3 Exemplu pentru o grilă de 12×12 pe 4 procesoare

Pentru acest exemplu se poate folosi următoarele valori inițiale:

```
-1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
 3 3 3 3 3 3 3 3 3 3 3 3
 3 3 3 3 3 3 3 3 3 3 3 3
 2 2 2 2 2 2 2 2 2 2 2 2
 2 2 2 2 2 2 2 2 2 2 2 2
 2 2 2 2 2 2 2 2 2 2 2 2
 1 1 1 1 1 1 1 1 1 1 1 1
 1 1 1 1 1 1 1 1 1 1 1 1
 1 1 1 1 1 1 1 1 1 1 1 1
 0 0 0 0 0 0 0 0 0 0 0 0
 0 0 0 0 0 0 0 0 0 0 0 0
-1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
```

Această metodă este foarte slabă dar este folosită datorită simplității ei. În continuare s-au realizat câteva aplicații care implementează această metodă prin folosirea de tehnici diferite pentru comunicația dintre task-uri (tehnici care sunt definite în standardul MPI).

A. Metoda Jacobi folosind operațiile MPI_Send/ MPI_Recv

În acest exemplu s-a realizat implementarea metodei Jacobi pentru o problemă cu dimensiunea problemei de 8×8 . Pentru realizarea comunicației s-au folosit funcțiile `MPI_Send` și `MPI_Recv`. De asemenea soluția este dată pentru exact 100 de iterații.

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3,...6 task-uri pe același nod și pe 6 noduri diferite. Se poate observa că dacă se crește

numărul de noduri performanța nu crește în mod semnificativ deoarece aplicația realizează foarte multe operații de comunicație, operații care se execută mult mai lent decât calculele pe care trebuie să le execute fiecare task.




Fig. 4 Metoda Jacobi folosind operațiile MPI_Send/ MPI_Recv

B. Metoda Jacobi folosind operația MPI_Sendrecv

În această secțiune sunt prezentate rezultatele obținute de o implementare a metodei Jacobi în care se folosește funcția `MPI_Sendrecv`. Această funcție realizează un schimb de date între 2 task-uri. Task-ul care apelează această funcție rămâne blocat până când se transmite un mesaj și se recepționează un mesaj.

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3,...6 task-uri pe același nod și pe 6 noduri diferite. Se poate observa că nu sunt diferențe foarte mari de performanță față de cazul în care se folosesc funcțiile `MPI_Send` și `MPI_Recv` pentru realizarea comunicației între task-uri.




Fig. 5 Metoda Jacobi folosind operația MPI_Sendrecv

C. Metoda Jacobi folosind comunicație "head to head"

În această secțiune sunt prezentate rezultatele obținute de o

implementare a metodei Jacobi în care se folosește funcția `MPI_Sendrecv` pentru a realiza o comunicație „head to head”.

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3...6 task-uri pe același nod și pe 6 noduri diferite. Se poate observa ca performanțele sunt mai mari față de implementarea anterioară.




Fig. 6 Metoda Jacobi folosind comunicație "head to head"

D. Metoda Jacobi folosind operații de tip nonblocking - versiunea 1

Această versiune folosește operații de comunicație de tip nonblocking pentru trimiterea și recepționarea mesajelor (acest lucru este realizat pentru a manipula mărimea bufferelor).

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3...6 task-uri pe același nod și pe 6 noduri diferite. Se poate observa că în această variantă a crescut semnificativ performanța față de cazul în care se foloseau operații de comunicație de tip blocking (`MPI_Sendrecv`).




Fig. 7 Metoda Jacobi folosind operații de tip nonblocking -versiunea 1

E. Metoda Jacobi folosind operații de tip nonblocking – versiunea 2

Această versiune folosește operații de comunicație de tip nonblocking pentru trimiterea și recepționarea mesajelor (acest lucru este realizat pentru a manipula mărimea bufferelor). În această variantă se anunță trimiterea prima dată permițând folosirea protocoalelor de rendezvous pentru primirea datelor de task-ul destinat minimizându-se costurile de sincronizare (acest lucru nu poate fi garantat)-

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3...6 task-uri pe același nod și pe 6 noduri diferite. Se poate observa că în această variantă performanțele sunt comparabile cu cele prezentate pentru prima variantă de folosire a operațiilor de tip nonblocking.




Fig. 8 Metoda Jacobi folosind operații de tip nonblocking -versiunea 1

F. Metoda Jacobi folosind transmitere sincronizată

Operațiile de transmitere sincronizate permite transmiterea fără realizarea buffer-ării. Acest lucru se poate realiza folosind funcția `MPI_Rsend`. Exemplul anterior a fost modificat să folosească această tehnică de transmitere.

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3...6 task-uri pe același nod și pe 6 noduri diferite.




Fig. 9 Metoda Jacobi folosind transmitere sincronizată

G. Metoda Jacobi folosind funcția MPI_Rsend

Într-o buclă simplă Jacobi la sfârșitul fiecărei iterații se poate folosi funcția MPI_Allreduce pentru a testa convergența soluției. Acest lucru furnizează un punct de sincronizare în program. În exemplul curent se folosește această sincronizare pentru a permite folosirea rutinei MPI_Rsend. În acest caz recepția (MPI_Irecv) este postată înaintea punctului de sincronizare iar transmisia (MPI_Rsend) este postată după punctul de sincronizare.

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3...6 task-uri pe același nod și pe 6 noduri diferite.




Fig. 10 G. Metoda Jacobi folosind funcția MPI_Rsend

H. Metoda Jacobi folosind funcția MPI_Irecv

Acest exemplu este asemănător cu cel anterior cu singura diferență că în locul funcției MPI_Rsend se folosește funcția MPI_Irecv (această funcție implementează o operație de transmisie de tip nonblocking).

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3...6 task-uri pe același nod și pe 6 noduri diferite.




Fig. 11 Metoda Jacobi folosind funcția MPI_Irecv

I. Metoda Jacobi folosind suprapunerea comunicației cu calculele

În acest exemplu calculele sunt împărțite în două părți: o parte care are nevoie de date de la alte procesoare și o parte care nu are nevoie. Partea care este independentă de alte task-

uri reprezintă interiorul domeniului (relativ la fiecare task) și partea care are nevoie de date externe reprezintă granița. Comunicația este pornită, se realizează comunicația pentru datele din interior, se termină comunicația și se realizează calculele pentru datele de la graniță. În acest fel se realizează o suprapunere a calculelor și a comunicației.

În continuare sunt date rezultatele (exprimate în MFlops) pentru cazul în care se creează 2,3...6 task-uri pe același nod și pe 6 noduri diferite. Se observă o creștere a performanței dacă se folosește această tehnică.




Fig. 12 Metoda Jacobi folosind suprapunerea comunicației cu calculele

VI. CONCLUZII

În urma testelor efectuate se pot observa diferențele performanțelor programelor paralele în funcție de tehnicile de comunicație care sunt folosite. În cadrul testelor care au fost realizate s-a subliniat importanța comunicării în cadrul programelor paralele prin evidențierea efectelor pe care o are asupra performanțelor. Aceste teste evidențiază valabilitatea legii lui Amdahl (prin dublarea numărului de noduri nu se dublează performanța).

REFERENCES

- [1] I. Foster: Designing and Building Parallel Programs, Addison-Wesley 1995
- [2] V. Niculescu: Modele de elaborare a algoritmilor paraleli, PhD. Thesis, Univ. Babes-Bolyai, 2002
- [3] Open MPI: Open Source High Performance Computing, www.open-mpi.org
- [4] Rohit Chandra, Leo Dagum, Dave Kohr, Dror Maydan, Jeff McDonald, Ramesh Menon, Parallel Programming in OpenMP, 2007
- [5] The Message Passing Interface (MPI) standard, [<http://www-unix.mcs.anl.gov/mpi/>], 2000.
- [6] Jacobi method, http://en.wikipedia.org/wiki/Jacobi_method
- [7] Ian Foster, Carl Kesselman, The Grid - Blueprint for a new computing infrastructure, Morgan Kaufmann, 1999
- [8] SKILLICORN, D.: Foundations of Parallel Programming, Cambridge International Series on Parallel Computations, 1994.
- [9] Reevaluating Amdahl's Law (1988). Communications of the ACM 31(5), pp. 532-33
- [10] Globus Toolkit, www.globus.org