

УДК 004:519.612.001.57

**О. М. Паулін**, д-р техн. наук,  
**I. В. Кривошап**

## ПОРІВНЯЛЬНИЙ АНАЛІЗ ЕФЕКТИВНОСТІ МЕТОДІВ МОДЕЛЮВАННЯ РОЗВ'ЯЗАННЯ СИСТЕМ ЛІНІЙНИХ АЛГЕБРАЇЧНИХ РІВНЯНЬ ПРИ ВИКОРИСТАННІ КЛАСТЕРА ТА ТЕХНОЛОГІЇ NVIDIA CUDA

У даній статті проводиться порівняння двох технологій для паралельних обчислень, кластерної та NVidia CUDA, на прикладі розв'язання систем лінійних алгебраїчних рівнянь при різних розмірностях системи. Ефективність оцінюється часом обчислень.

**Ключові слова:** кластер, GPU, CUDA, моделювання, ефективність.

**O. Paulin, ScD.,  
I. Kryvoshap**

## COMPARATIVE ANALYSIS OF MODELING METHODS FOR SOLVING SYSTEMS OF LINEAR ALGEBRAIC EQUATIONS WHEN USING CLUSTERS AND NVIDIA CUDA TECHNOLOGY EFFICIENCY

This article compares the two technologies for parallel computing, cluster and NVidia CUDA, on example of solving systems of linear algebraic equations with different dimensions of the system. Efficiency is estimated by time of computing.

**Keywords:** cluster, GPU, CUDA, modeling, efficiency.

**О. Н. Паулин, д.т.н.,  
І. В. Кривошап**

## СРАВНИТЕЛЬНЫЙ АНАЛИЗ ЭФФЕКТИВНОСТИ МЕТОДОВ МОДЕЛИРОВАНИЯ РЕШЕНИЯ СИСТЕМ ЛИНЕЙНЫХ АЛГЕБРАИЧЕСКИХ УРАВНЕНИЙ ПРИ ИСПОЛЬЗОВАНИИ КЛАСТЕРА И ТЕХНОЛОГИИ NVIDIA CUDA

В данной статье проводится сравнение двух технологий для параллельных вычислений, кластерной и NVidia CUDA, на примере решения систем линейных алгебраических уравнений при различных размерностях системы. Эффективность оценивается временем вычислений.

**Ключевые слова:** кластер, GPU, CUDA, моделирование, эффективность.

**Вступ.** У сучасних умовах розвитку обчислювальної техніки актуальними є проблеми створення нових підходів до підвищення її ефективності. При цьому з'являються можливості побудови інформаційно-обчислювальних систем нового класу за рахунок застосування більш ефективних методів їх організації, а саме за рахунок розробки паралельних методів обробки інформації.

Організація паралельних обчислень для задач лінійної алгебри (ЛА) є предметом теоретичних і експериментальних досліджень для подальшого зростання продуктивності обробки великорозмірних інформаційних масивів у приладобудуванні, робототехніці, біомедицині. Зокрема, однією із базових матричних операцій ЛА в системах розпізнавання образів,

аналізу і оброблення зображень, системах реконструктивної томографії є розв'язання систем лінійних алгебраїчних рівнянь (СЛАР) високих порядків та обертення великорозмірних матриць [1]. При цьому велика обчислювальна складність матричних операцій, а також високі вимоги до точності і часу виконання обумовлюють доцільність їх реалізації на паралельних спеціалізованих обчислювальних системах.

В даній роботі буде проведене порівняння найбільш популярної технології організації паралельних обчислень – кластерної [2] із відносно новою технологією NVidia CUDA, на рівні архітектури та результатів, отриманих під час розв'язання конкретної задачі за допомогою цих технологій.

**Кластери.** Кластер – це набір комп'ютерів (обчислювальних вузлів), об'єднаних деякою

© Паулін О.М., Кривошап І.В., 2012

комунікаційною мере-жею. Кожен обчислювальний вузол має свою оперативну пам'ять і працює під управлінням своєї операційної системи. Найбільш поширеним є використання однорідних кластерів, тобто таких, де всі вузли абсолютно однакові за своєю архітектурою та продуктивністю. Серед Top 500 найпродуктивніших систем саме кластери складають більшу частину списку [2].

Для об'єднання комп'ютерів кластера використовується два види мереж: керувальна та комунікаційна. Через керувальну мережу здійснюється керування системою, запуск програм на кластері за допомогою керувальної ПЕОМ. Як правило, для цього використовується мережа Fast Ethernet, оскільки швидкості передачі цієї мережі цілком вистачає для виконання потрібних завдань. Комуникаційна мережа повинна мати якомога більшу пропускну здатність, щоб час передавання даних і затримки передачі повідомень були мінімальними. Для цього найліпше підходить мережа SCI, яка має пікову пропускну швидкість 10 Гбайт/с, й затримку 4 мкс [2]. Проте вартість прокладання мережі SCI є високою, тому, зазвичай, на практиці у невеликих неприбуткових установах як комунікаційну мережу використовують мережу Fast Ethernet / Gigabit Ethernet, яка є набагато дешевшою за SCI, але, у свою чергу має й меншу швидкість пропускання даних – 12 Мбайт/с (128 Мбайт/с для Gigabit Ethernet) і більшу латентність – 50 мкс [2]. Саме через те, що зв'язок між комп'ютерами проходить через повільну мережу, вибираються такі алгоритми для розв'язання задач, які мають малу частку операцій передавання даних у порівнянні з операціями обчислення. Загальна схема обчислювального кластера подана на рис. 1.

Основними перевагами використання кластерної архітектури є:

- використання комп'ютерів із різними характеристиками;
- підтримка ОС Linux та Windows;
- низька вартість організації кластера;
- можливість змінення кількості вузлів кластеру;

об'єднання комп'ютерів у мережі стандарту Ethernet.

Проте кластерна архітектура має й недоліки:

- складність програмування;
- висока вартість організації обчислювальних монолітних кластерів;
- потреба у великій кількості ПЕОМ [1].

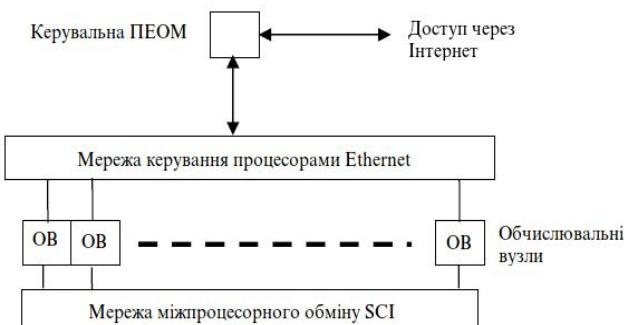


Рис. 1. Схема обчислювального кластера

При складанні програм для обчислювального кластера використовується бібліотека паралельного програмування MPI (Message Passing Interface). Рекомендується застосовувати її безкоштовну реалізацію – MPICH. MPI є бібліотекою функцій міжпроцесорного обміну повідомленнями та містить близько 300 функцій.

**Технологія NVidia CUDA.** CUDA (Compute Unified Device Architecture) – це архітектура паралельних обчислень від NVidia, що дає змогу істотно збільшити обчислювальну продуктивність завдяки використанню графічних процесорів [3].

Термін графічний процесор (GPU) був вперше використаний корпорацією NVidia для позначення, того що графічний прискорювач, який першочергово використовувався для пришившення тривимірної графіки, став потужним процесором, здатним для розв'язання широкого класу задач, не пов'язаних з графікою.

Нині сучасні GPU являють собою масивно-паралельні обчислювальні пристрой з дуже великою швидкодією (більш одного терафлопа) та великим об'ємом власної пам'яті [4]. На відміну від сучасних універсальних централь-

них процесорів (CPU), відеочіпи призначені для паралельних обчислень з великою кількістю арифметичних операцій. І значно більше число транзисторів GPU працює за прямим призначенням обробки масивів даних, а не керує виконанням нечисленних послідовних обчислювальних потоків [5]. Схема того, скільки місця в CPU і GPU займає різноманітна логіка, представлена на рис. 2.

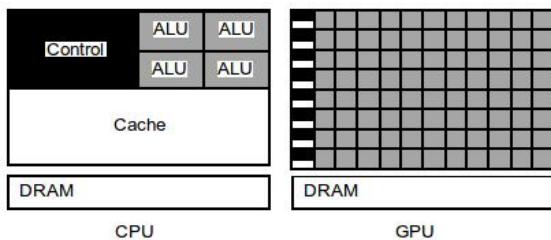


Рис. 2. Схема складових елементів  
CPU та GPU

Для розв'язання задач CUDA використовує дуже велику кількість паралельно виконуваних потоків, при цьому зазвичай одному потокові відповідає один елемент обчислювальних даних. Усі запущені на виконання потоки організовані у ієрархії (рис. 3).

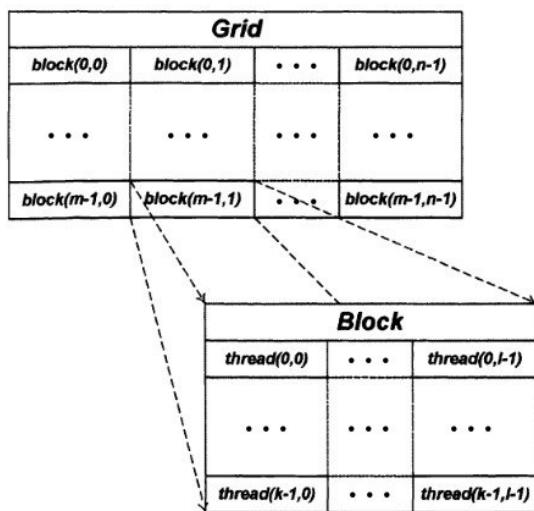


Рис. 3. Ієрархія потоків у CUDA

Верхній рівень ієрархії – сітка (grid) – відповідає усім потокам, які виконують дане ядро. Верхній рівень – одновимірний або двовимірний масив блоків (block). Кожний блок – це одновимірний, двовимірний або тривимірний

масив потоків (thread). При цьому усі блоки, що утворюють сітку, мають однакові розмірність та розмір. Кожний блок у сітці має свою адресу, як складається з одного або двох не від'ємних чисел (індекс блоку в сітці). Аналогічно кожен потік у блокі також має свою адресу – одне, два або три невід'ємних числа, що задають індекс потоку у блокі [4].

При написанні програм, використовуючи технологію CUDA, також слід звести до мінімуму кількість операцій передавання даних між центральним процесором та відеоадаптером, але цей показник не є таким критичним, як у кластерах, оскільки час передавання даних у даному випадку є сумірним із часом виконання обчислень. Це обумовлено тим, що канал передачі даних залежить лише від ширини шини передачі даних між процесором та відеоадаптером. У сучасних системах він має ширину у 32 або 64 біти. Щодо кількості операцій передачі даних всередині відеоадаптеру між графічним процесором та графічною пам'яттю, звісно її також рекомендується зменшити, але оскільки ширина шини передачі даних сягає 64–256 біт, то часто на ній можна не звертати увагу.

Переваг використання технології CUDA такі:

інтерфейс програмування додатків CUDA заснований на стандартній мові програмування Cі з розширеннями, що спрощує процес вивчення і впровадження архітектури CUDA;

CUDA забезпечує доступ до поділюваної між потоками пам'яті розміром 16 Кб на мультипроцесор, яка може бути використана для організації кешу з широкою смugoю пропускання;

ефективна передача даних між системною і відеопам'яттю;

нема потреби в графічних API з надмірністю і накладними витратами;

лінійна адресація пам'яті, можливість запису за довільними адресами;

апаратна підтримка ціличисельних і бітових операцій;

недорогое апаратне забезпечення (відеоадаптер).

Що ж до недоліків та обмежень CUDA, то до них можна віднести:

відсутність підтримки рекурсії для виконуваних функцій;

мінімальна ширина блоку в 32 потоки;  
закрита архітектура CUDA, що належить NVIDIA [1].

**Моделювання та порівняння результатів.** Для прикладу обрана програма для розв'язання систем лінійних алгебраїчних рівнянь (СЛАР) методом Гауса.

Результати обчислень були отримані на кластерах «СКИФ Cyberia» Томського державного університету (ТДУ), кожен обчислювальний вузол якого має в собі два двоядерні процесори Intel Xeon 5150 з частотою 2,6 Гц [6], Московського енергетичного інституту (МЕІ), кожен обчислювальний вузол якого має в собі два двоядерних процесори з частотою 2,2 Гц [7]. Заміри були проведені при задіянні чотирьох вузлів на кожному з кластерів. Результати обчислень із використанням технології NVidia CUDA були отримані на тестовому комп'ютері ОНПУ з процесором Intel Pentium Dual E2160 з частотою 1,8 Гц та наявним відеоадаптером NVidia GeForce GT620, що містить у собі 96 обчислювальних ядер з частотою 700 МГц кожне [1]. Порівняльні результати наведено у таблиці.

Згідно з даними у таблиці, можна порівняти час обчислень СЛАР на кластерах та за допомогою розробленої програмної системи з використанням технології CUDA.

Порівнюючи результати процесу моделювання, при різних розмірностях системи N, що були отримані при використанні кластерів та технології NVidia CUDA, можна побачити, що час розв'язання на кластері МЕІ при N=500 приблизно у 2 рази більший за час виконання на GPU. Час розв'язання на кластері ТДУ при N=1000 приблизно дорівнює часу виконання на GPU. Слід також зауважити, що програма розв'язання СЛАР на кластері ТДУ не враховує час передавання даних від керувального вузла до обчислюваних вузлів, який при вели-

ких розмірностях системи може бути значним у порівнянні з отриманими результатами.

### 1. Результати обчислень часу розв'язання СЛАР, мс

Розмірність системи N	Кластер ТДУ	Кластер МЕІ	GPU ОНПУ
500	-	150	71
1000	490	-	556

**Висновки.** Використання графічних процесорів та технології NVidia CUDA є перспективним тому, що її реалізація є менш затратною, а отримані результати по-рівнювані із результатами, отриманими за допомогою кластерів. Менша затратність полягає в тому, що потрібний лише один персональний комп'ютер із підтримуваним відеоадаптером, а для значного підвищення продуктивності слід лише встановити більш потужну (з більшою кількістю обчислювальних ядер та більшим об'ємом пам'яті) відеокарту. Для суттєвого підвищення продуктивності обчислювальних систем варто об'єднати комп'ютери із графічними процесорами у кластер.

### Список використаної літератури

1. Кривошап, І. В. Програмна система для розв'язання систем лінійних алгебраїчних рівнянь на багатоядерних процесорах / І. В Кривошап // Дипломна робота магістра. – Одеса : 2012. – 107 с.
2. Шпаковский, Г. И. Реализация параллельных вычислений: MPI, OpenMP, кластеры, грид, многоядерные процессоры, графические процессоры, квантовые компьютеры / Г. И. Шпаковский. – Минск : БГУ, 2011. – 176 с.:ил.
3. Что такое CUDA? [Електронний ресурс] – Режим доступу: <http://www.nvidia.ru/>. – Назва з екрану.
4. Боресков, А. В. Основы работы с технологией CUDA / А. В. Боресков, А. А. Харламов. – Москва : ДМК Пресс, 2010. – 232 с.:ил.
5. Берилло, Алексей. NVidia CUDA – не-графические вычисления на графических процессорах [Електронний ресурс] – Режим доступу: <http://www.ixbt.com/video3/cuda-1.shtml> (23.09.2009). – Назва з екрану.

6. Высокопроизводительные вычисления на кластерах / Д .А. Беликов, И. В. Говязов, Е. А. Данилкин, В. И. Лаева, С. А. Проханов, А. В. Старченко. – Томск : ТНУ, 2008. – 198 с.

7. Лю Лян . Исследование эффективности параллельных вычислений на кластере Московского энергетического института (технического университета) / Лю Лян // Автореферат диссертации на соискание ученой степени кандидата технических наук. – Москва : – 2007. – 20 с

Отримано: 15.10.2012

#### References

1. Kryvoshap, I. V. The software system for solving systems of linear algebraic equations on multicore processors. Master's diploma work / I. V. Kryvoshap. – Odessa, 2012. – 107 p. [in Ukrainian].

2. Shpakovsky, G. I. The implementation of parallel computings: MPI, OpenMP, clusters, grid, multicore processors, graphics processors, quantum computers / G. I. Shpakovsky. – Minsk : Belarusian State University, 2011. – 176 p. [in Russian].

3. What is CUDA? [E-resource] — Access mode: <http://www.nvidia.ru> / Title from screen [in Russian].

4. Boreskov, A. V. Technology basics CUDA / A. V. Boreskov, A. A. Kharlamov. – Moscow : DMK Press, 2010. – 232 p. [in Russian].

5. Beryllo, Alex. NVidia CUDA–non-graphic computing on GPU [E-resource] – Access mode: <http://www.ixbt.com/video3/cuda-1.shtml> (23.09.2009). – Title from screen [in Russian].

6. High-performance computing clusters / D. A. Belikov, I. V. Govyazov, Ye.A. Danilkin, V. I. Laeva, S.A. Prokhanov, A. V. Starchenko. – Tomsk : TNU, 2008. – 198 p. [in Russian].

7. Liu Liang. Study of the effectiveness of parallel computing on a cluster of Moscow Power Engineering Institute (Technical University) / Liu Liang. // Dissertation for the degree of Doctor of Science. – Moscow : – 2007 [in Russian].



Паулін  
Олег Миколайович,  
д-р техн. наук, проф. каф.  
Системного програмного  
забезпечення Одеського  
нац. політехн. ун-ту,  
тел: (0482) 44-22-89.  
E-mail: paulin@te.net.ua



Кривошап  
Ігор Васильович,  
аспірант каф. Системного  
програмного забезпечення  
Одеського нац. політехн.  
ун-ту,  
тел: (093) 719-70-06.  
E-mail: x\_fs@ukr.net