



وظيفة برمجة متوازية

OpenMP && CUDA

January 31 , 2024

تقديم: أحمد عبدالله

السؤال الأول:

الهدف من هذا السؤال هو ايجاد قيمة التكامل بطريقة عددية للمنطقة الواقعة تحت منحنى X^2 ، في المجال $[0,1]$, وذلك من خلال اتباع طريقة التجزئة والتي تقوم على تقسيم المساحة الكلية إلى مساحات منفصلة جزئية يمكن حسابها، فتكون المساحة الكلية هي مجموع المساحات الجزئية (بتقريب مقبول).

و للقيام بذلك تم كتابة برنامج متوازي باستخدام واجهة OpenMP لحساب هذه المساحة عن طريق توزيع حساب المساحات الجزئية بين عدة نياشب ثم تجميعها عند النياشب الرئيسي لتعبر عن المساحة الكلية.

حيث تم تقسيم المساحة الكلية الى مستطيلات ذات ارتفاعات متزايدة ولكن لها العرض نفسه وعددها 1000000، و بحيث يقوم كل نياشب بحساب المساحة الجزئية للمستطيلات المخصصة له، ويتم دمج النتائج للحصول على المساحة الإجمالية. ثم تتم طباعة النتيجة النهائية على وحدة التحكم.

حيث من خلال هذه التعليمية

#pragma omp parallel for reduction(+:total_area)

نقوم بالبداية بمنطقة متوازية (parallel region) مع حلقة تكرارية و تضمن بأن المتحول total_area خاص بكل نياشب على حدة، وفي نهاية الحلقة يتم دمج النتائج الجزئية للحصول على الناتج النهائي.

و كان الخرج على الشكل التالي:

```
ahmad_abdallah@master:/nfs/Ahmad_Abdallah/OpenMp$ make run
./out
Total area under the curve: 0.333333
ahmad_abdallah@master:/nfs/Ahmad_Abdallah/OpenMp$
```

ما هو التنفيذ المتوازي الأفضل لهذه المسألة OpenMP أو MPI أو الاثنين معاً؟
في العموم لنذكر خصائص كل من الطريقتين وإيجابياتها.

بالنسبة ل OpenMP :

- نموذج برمجة متوازي للذاكرة المشتركة، أي أن تتمتع الاجرائيات (processes) أو النوى (cores) بإمكانية الوصول إلى جزء مشترك من الذاكرة.
- سهل الاستخدام مع توجيهات المترجم (compiler directives) لتحقيق الموازاة.
- عادة ما تكون أسهل في التنفيذ والفهم للمهام التي يمكن موازنتها داخل جهاز واحد.

و في مسألتنا قمنا بتطبيق ال OpenMP من خلال توزيع حساب المساحات الجزئية للمستطيلات بين عدة نياسب تعمل على نفس العقدة (الحاسب). يمكن تعيين مجموعة فرعية من المستطيلات لكل نيسب لحساب المساحات الجزئية، ومن ثم يمكن دمج النتائج للحصول على المساحة الاجمالية.

بالنسبة ل MPI:

- مناسب تمامًا لأنظمة الذاكرة الموزعة.
- يتطلب تواصل بين العمليات، من خلال عمليات (ارسال/ استقبال) وهذا ما يزيد زمن التواصل
- يُستخدم عادةً في مجموعات الحوسبة عالية الأداء.

في مسألتنا يمكن تطبيق ال MPI من خلال تقسيم حساب المساحات الجزئية للمستطيلات على عدة عقد (حواسب) ومن ثم يمكن جمع النتائج ودمجها للحصول على المساحة الإجمالية.

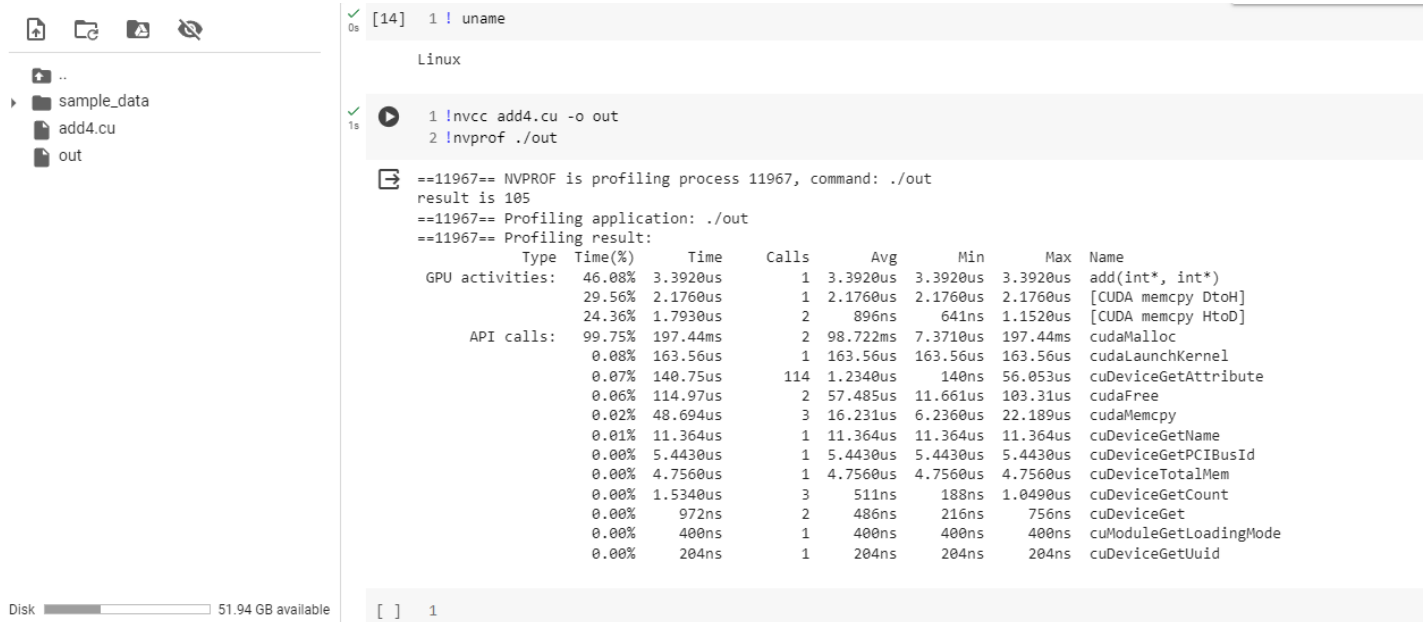
الجمع بين OpenMP و MPI يمكن تطبيقه في مسألتنا من خلال تقسيم حساب المساحات الجزئية للمستطيلات على عدة عقد، وضمن كل عقدة يتم توزيع مجموعة المساحات الخاصة بها على عدة نياسب مشتركة بالذاكرة و بذلك نكون قد خففنا زمن التواصل الذي سيكون اكبر فيما لو استخدمنا MPI لوحدها و سيتم الاستفادة من موارد حاسوبية اكبر و ايجاد الحل بوقت اقل ربما من استخدام OpenMP لوحدها.

ولكنني اجد و تبعا لمعطيات المسألة ان تطبيق OpenMP لوحدها افضل، حيث اننا نواجه مسألة بسيطة لا تحتاج الى موارد حاسوبية كبيرة و بالتالي يمكننا الاستفادة من فكرة الذاكرة المشتركة و تطبيق OpenMP ، من خلال تقسيم عبء العمل والحساب بين النياسب التي تنقسم نفس الذاكرة. و بذلك نكون قد خففنا زمن التواصل بشكل كبير وحصلنا على نتائج جيدة ضمن وقت جيد.

قد يكون MPI او الجمع بين الطريقتين افضل ولكن في حالة إذا كنا نتعامل مع نظام ذاكرة موزعة، و لدينا معطيات المسألة اعقد و بالتالي نحتاج الى موارد حاسوبية اكثر.

السؤال الثاني:

1) لايجاد البرنامج الخطأ ضمن البرامج الأربعة تم تشغيل كل منها على حدا و كانت النتائج كالتالي:
بالنسبة للبرنامج الأول



```
[14] 1 ! uname
Linux

1 ! nvcc add4.cu -o out
2 ! nvprof ./out

==11967== NVPROF is profiling process 11967, command: ./out
result is 105
==11967== Profiling application: ./out
==11967== Profiling result:
Type      Time(%)      Time      Calls      Avg      Min      Max      Name
GPU activities: 46.08%  3.3920us    1  3.3920us  3.3920us  3.3920us  add(int*, int*)
                29.56%  2.1760us    1  2.1760us  2.1760us  2.1760us  [CUDA memcpy DtoH]
                24.36%  1.7930us    2    896ns   641ns   1.1520us  [CUDA memcpy HtoD]
API calls: 99.75% 197.44ms    2  98.722ms  7.3710us  197.44ms  cudaMalloc
                0.08% 163.56us    1 163.56us 163.56us 163.56us  cudaLaunchKernel
                0.07% 140.75us   114 1.2340us 140ns   56.053us  cuDeviceGetAttribute
                0.06% 114.97us    2  57.485us 11.661us 103.31us  cudaFree
                0.02% 48.694us    3 16.231us 6.2360us 22.189us  cudaMemcpy
                0.01% 11.364us    1 11.364us 11.364us 11.364us  cuDeviceGetName
                0.00% 5.4430us    1  5.4430us 5.4430us 5.4430us  cuDeviceGetPCIBusId
                0.00% 4.7560us    1  4.7560us 4.7560us 4.7560us  cuDeviceTotalMem
                0.00% 1.5340us    3    511ns   188ns   1.0490us  cuDeviceGetCount
                0.00% 972ns      2    486ns   216ns   756ns    cuDeviceGet
                0.00% 400ns      1    400ns   400ns   400ns    cuModuleGetLoadingMode
                0.00% 204ns      1    204ns   204ns   204ns    cuDeviceGetUuid
```

و اعطى الخرج المتوقع منه حيث كان الهدف من هذا البرنامج هو جمع القيمتين a, b والنتيجة التي اعطاها الخرج كانت قيمة صحيحة و بالمرور على البرنامج وقراءته و جدت ان البرنامج صحيح و لا يوجد فيه اي خطأ منطقي او خطأ في التنفيذ.

بالنسبة للبرنامج الثاني :

==18972== NVPF is profiling process 18972, command: ./out

5.000000	6.000000	7.000000	8.000000	9.000000	10.000000	11.000000	12.000000
15.000000	16.000000	17.000000	18.000000	19.000000	20.000000	21.000000	22.000000
25.000000	26.000000	27.000000	28.000000	29.000000	30.000000	31.000000	32.000000
35.000000	36.000000	37.000000	38.000000	39.000000	40.000000	41.000000	42.000000
45.000000	46.000000	47.000000	48.000000	49.000000	50.000000	51.000000	52.000000
55.000000	56.000000	57.000000	58.000000	59.000000	60.000000	61.000000	62.000000
65.000000	66.000000	67.000000	68.000000	69.000000	70.000000	71.000000	72.000000
75.000000	76.000000	77.000000	78.000000	79.000000	80.000000	81.000000	82.000000
85.000000	86.000000	87.000000	88.000000	89.000000	90.000000	91.000000	92.000000
95.000000	96.000000	97.000000	98.000000	99.000000	100.000000	101.000000	102.000000
105.000000	106.000000	107.000000	108.000000	109.000000	110.000000	111.000000	112.000000
115.000000	116.000000	117.000000	118.000000	119.000000	120.000000	121.000000	122.000000
125.000000	126.000000	127.000000	128.000000	129.000000	130.000000	131.000000	132.000000
135.000000	136.000000	137.000000	138.000000	139.000000	140.000000	141.000000	142.000000
145.000000	146.000000	147.000000	148.000000	149.000000	150.000000	151.000000	152.000000
155.000000	156.000000	157.000000	158.000000	159.000000	160.000000	161.000000	162.000000
165.000000	166.000000	167.000000	168.000000	169.000000	170.000000	171.000000	172.000000
175.000000	176.000000	177.000000	178.000000	179.000000	180.000000	181.000000	182.000000
185.000000	186.000000	187.000000	188.000000	189.000000	190.000000	191.000000	192.000000
195.000000	196.000000	197.000000	198.000000	199.000000	200.000000	201.000000	202.000000
205.000000	206.000000	207.000000	208.000000	209.000000	210.000000	211.000000	212.000000
215.000000	216.000000	217.000000	218.000000	219.000000	220.000000	221.000000	222.000000
225.000000	226.000000	227.000000	228.000000	229.000000	230.000000	231.000000	232.000000
235.000000	236.000000	237.000000	238.000000	239.000000	240.000000	241.000000	242.000000
245.000000	246.000000	247.000000	248.000000	249.000000	250.000000	251.000000	252.000000
255.000000	256.000000	257.000000	258.000000	259.000000	260.000000	261.000000	262.000000
265.000000	266.000000	267.000000	268.000000	269.000000	270.000000	271.000000	272.000000
275.000000	276.000000	277.000000	278.000000	279.000000	280.000000	281.000000	282.000000
285.000000	286.000000	287.000000	288.000000	289.000000	290.000000	291.000000	292.000000
295.000000	296.000000	297.000000	298.000000	299.000000	300.000000	301.000000	302.000000

Type	Time(%)	Time	Calls	Avg	Min	Max	Name
GPU activities:	98.61%	1.2443ms	1	1.2443ms	1.2443ms	1.2443ms	vector_add(float*, float*, float*, int)
	0.99%	12.512us	2	6.2560us	6.1120us	6.4000us	[CUDA memcpy HtoD]
	0.40%	5.0240us	1	5.0240us	5.0240us	5.0240us	[CUDA memcpy DtoH]
API calls:	98.99%	193.76ms	3	64.586ms	3.0840us	193.75ms	cudaMalloc
	0.69%	1.3557ms	3	451.89us	25.002us	1.2960ms	cudaMemcpy
	0.13%	262.56us	3	87.519us	8.0290us	204.09us	cudaFree
	0.10%	189.39us	1	189.39us	189.39us	189.39us	cudaLaunchKernel
	0.07%	139.81us	114	1.2260us	140ns	56.036us	cuDeviceGetAttribute
	0.01%	10.882us	1	10.882us	10.882us	10.882us	cuDeviceGetName
	0.00%	5.2660us	1	5.2660us	5.2660us	5.2660us	cuDeviceGetPCIBusId
	0.00%	5.2160us	1	5.2160us	5.2160us	5.2160us	cuDeviceTotalMem
	0.00%	2.6690us	2	1.3340us	181ns	2.4880us	cuDeviceGet
	0.00%	1.5220us	3	507ns	201ns	1.0140us	cuDeviceGetCount

ايضا اعطى البرنامج الثاني اعطى الخرج المتوقع له حيث الهدف منه هو حساب مجموع عناصر مصفوفتين بطول 10000 الاولى عناصرها بالترتيب من 0 الى 9999 و الثانية عناصرها جميعها 5، واعطت الخرج المتوقع بشكل صحيح اي انه لا يوجد خطأ على مستوى التنفيذ.

لكن هناك خطأ على مستوى الكود وذلك في الاستفادة من فكرة التوازي و هو انه تم تعريف block واحد يحوي 256 نيسب جميعها تقوم بنفس المهمة اي اننا لم نستفد من اي نيسب تم تعريفه لان نيسب ال main لوحده قام باجراء الحساب مرة و باقي 256 نيسب قاموا بتكرار العملية ذاتها، وهذا خطأ كبير للغاية. أثر هذا الخطأ هو تكرار الكود نفسه 256 مرة و هذا سيزيد من التنفيذ. وهذا ما توضحه هذه الصورة.

```
__global__ void vector_add(float *out, float *a, float *b, int n) {
    for(int i = 0; i < n; i += 1){
        out[i] = a[i] + b[i];
    }
}

// Executing kernel
vector_add<<<1,256>>>>(d_out, d_a, d_b, N);
```

بالنسبة للبرنامج الثالث:

يشبه البرنامج الثاني من حيث الهدف حيث ولكن الفرق في المصفوفة الثانية التي قيمها جميعها 26 و المصفوفة الاولى عناصرها هي من 1 الى 10000 بالترتيب و اعطت الخرج المتوقع منها.

ولكن بالنسبة للبرنامج الثالث فقد عمل بشكل صحيح واستفاد من التوازي بشكل كامل. ولا توجد فيه اي خطأ لا على مستوى التنفيذ ولا على مستوى منطق التوازي.

```
__global__ void vector_add(float *out, float *a, float *b, int n) {
    int index = threadIdx.x;
    int stride = blockDim.x;

    for(int i = index; i < n; i += stride){
        out[i] = a[i] + b[i];
    }
}
```

بينما البرنامج الرابع :

[illegible]

هو الذي يحتوي خطأ في التنفيذ حيث لم يتم بالذي مفروض ان يقوم به.
والخطأ موجود في هذا القسم:

```
// Executing kernel
vector_add<<<1,256>>>>(d_out, d_a, d_b, N);
```

الخطأ هو أن النواة يتم تشغيلها بكتلة واحدة و 256 نيسب لكل كتلة ، و نحن لدينا احجام المصفوفات a, b, out هو 10000، وهو أكبر من عدد النياسب 256 ضمن ال grid هذا يعني أنه لن تتم معالجة جميع عناصر المصفوفات بواسطة النياسب التي تم تشغيلها، مما يؤدي إلى نتائج غير صحيحة وهذا ما توضحه الصورة حيث نجد ان المجموع وصل الى القيمة $282 = 16 + 256$ و باقي عناصر المصفوفة اصفار.

حيث فقط اول 256 قيمة تمت معالجتهم بشكل صحيح واما باقى القيم لم تتم معالجتها.

ببساطة يمكن حل المشكلة من خلال زيادة عدد النياسب ضمن الكتلة الواحدة بحيث تحتوي 10000 نيسب او زيادة عدد الكتل بحيث يكون لدينا مجموع نياسب الكتل اكبر او يساوي 10000.

(2) للاستفادة من المعالجات المتوازية المتعددة في وحدة معالجة الرسومات CUDA لتحسين أداء البرنامج، يمكن تشغيل النواة باستخدام كتل متعددة بدلا من كتلة واحدة فقط بذلك، نكون قد وزعنا عبء العمل عبر عدة SMS والسماح لهم بمعالجة البيانات بالتوازي.

تم اجراء التعديلات على البرنامج cu4.Vec_a حيث تم اضافة حلقة تكرارية للمرور على الاحجام المختلفة (32,128,512,1024). لكل حجم كتلة، يتم حساب عدد الكتل المطلوبة بناء على العدد الإجمالي للعناصر N وحجم الكتلة. وقد تم تشغيل البرنامج و اعطى نتائج صحيحة.