

最適化①…

ご購入はこちら

処理ベクタ長のチューニング

本橋 弘臣




図1 カネル・コード実行時のデータの流れ

● カネル・コードの実行時の基本動作

図1にカネル・コード実行時のデータの流れを示します。GPUによる演算処理を単純して考えると、次の基本動作の組み合わせになります。

- ① VRAMから入力データを読み出す
- ② GPU内のプロセッサ・エレメント (PE) で演算処理を行う
- ③ VRAMに出力データを書き込む

全ての処理を最適に高速化することができれば、GPU演算処理全体が最短の時間で実行可能になります。

ここで②で実行する処理の中で最も軽い処理は何なのかを考えてみると、GPUでは何も演算処理は行わずにVRAMから読み出した入力データをそのまま出力する、言い方を変えるとデータ・コピー処理になります。

● データ入力/出力の処理を最適化することが重要

GPU演算処理を最適化する際には、カネル・コードでの演算アルゴリズムを工夫したり、共有メモリの使い方などを改善したりすることも重要です。しかし、仮に②の処理を最適化できたとしても、①と③の

処理が最適化されていないと、①/③の部分がボトルネックとなってしまう、GPU演算処理全体としては高速になりません。つまり、まずは足回りとなる①と③の処理を高速化/最適化しておく必要があるということです。

そこで、本稿ではデータ・コピー処理を行うカネル・コードを題材として取り上げます。OpenCLで利用可能なさまざまな仕組みを活用することで、処理性能(ここではデータ・コピー速度)が大きく変化します。

コード①…データ・コピー処理

・データ型: uint, ・データ個数: 8

● uintデータを8個コピーするプログラム

カネル・コードでuintのデータを8個コピーするプログラムです。プログラムはchap6/opencl-copy-uintに格納されています。

▶ カネル・コードの内容

リスト1(a)にカネル・コードを示します。X方向のグローバルIDを参照して、各スレッドごとにコピーすべきデータを決定しています。

▶ ホスト・コードの内容

ホスト・コードのうち、主要となる部分をリスト1(b)に示します。GPUからの出力データをホスト・メモリ側にコピーした後で、GPUへの入力データと出力データを比較して完全一致していることをチェックしています。

● 実行結果

実行結果を次に示します。

```
$ ./main
:
[Kernel] dest[0] <- src[0]
[Kernel] dest[1] <- src[1]
[Kernel] dest[2] <- src[2]
[Kernel] dest[3] <- src[3]
[Kernel] dest[4] <- src[4]
[Kernel] dest[5] <- src[5]
```