

工夫次第で処理速度は10倍以上に！
ボトルネックになりがちなコピー処理の高速化も

ご購入はこちら

最適化③…浮動小数点数対応と非同期実行，ゼロ・コピー処理

本橋 弘臣

表1 OpenCLに用意されている最適化手法

本稿では浮動小数点数への対応を行った上で，非同期実行化とゼロ・コピー処理の活用について紹介する

GPUの性能最適化手法	変更箇所	備考
ローカル・ワーク・サイズの最適化	ホスト・コード	説明済み
処理ベクタ長の最適化	カーネル・コード	説明済み
GPU処理の非同期実行化	ホスト・コード	本稿で説明
ゼロ・コピー処理の活用	ホスト・コード	本稿で説明

ここまでで，まだ説明していない最適化方法を含めると，OpenCLではGPUの最適化手法として表1のような方法が用意されています。

本稿では，GPUで次の処理を行うプログラムを題材に，処理性能を最適化していきます。

- 機能：大量のfloatデータに対して加算処理を行う ($C = A + B$)
- 処理対象のデータ個数：変数a, b, c各データが全て128M個(512Mバイト)

① 浮動小数点数(float)への対応と最適化

コード①：最適化前のベース

・データ型：float，・lws：1，・gws：128M

● ソースコードの内容

▶ データ型をfloatに変更

最適化を行う前のシンプルなコードを最初に示します。プログラムはchap8/openc1-add-floatに格納されています。まずカーネル・コードはリスト1(a)(次頁)のように至って単純なコードです。次に，ホスト・コードの主要部分をリスト1(b)に示します。このコードとは，カーネル・コードで取り扱うデータ

の型がfloatに変わっただけで，第2部 第6章までに登場したサンプル・プログラムと比べて，特に新しい要素は含まれていません。

▶ GPU処理時間の測定&表示機能を追加

リスト1(b)には示していませんが，実際のホスト・コードにはGPUで実行している各処理ステップごとの処理時間を測定して，プログラムの最後で処理時間を表示する機能が追加されています。このため，ホスト・コードの先頭では，リスト1(c)のように，まずベンチマーク・テストの実行回数分のイベント・オブジェクト変数を宣言しています。event変数が2次元配列になっているのは，次に示す4つのGPU処理ステップごとの処理時間を測定するようにしているからです(表2)。

表2 新たにコードに追加したGPUの処理時間測定機能における測定項目

4つの処理ステップごとに処理時間を測定する。そのためevent変数が2次元配列になっている

測定項目	使用する変数
GPU入力データのコピー (mem_obj_a：ホスト→VRAM)	event [][0]
GPU入力データのコピー (mem_obj_b：ホスト→VRAM)	event [][1]
カーネル実行	event [][2]
GPU出力データのコピー (mem_obj_c：VRAM→ホスト)	event [][3]

● 実行結果…GPU処理速度は0.8Gバイト/s

リスト2にこのopenc1-add-floatプログラムの実行結果を示します。ホスト・メモリ上のパuffアをCPUが初期化するのに1761msの時間が掛かっているので，CPU→Memoryの書き込み速度は0.9Gバイト/sに過ぎなかったことが分かります。一方でGPUのカーネル・コードが128M個のfloat値(AとB)を加算して，加算結果をVRAMに書き込むのに平均で