

Android スマートフォンにおける NEON 命令を用いた階層的並列処理

Hierarchical Parallel Processing Using NEON Instructions on Android Smartphone

西倉 佑騎†
Yuki Nishikura

吉田 明正†
Akimasa Yoshida

1 はじめに

ARM マルチコアを搭載した Android スマートフォンは、マルチコアによるスレッドレベル並列処理と NEON 命令 (ARM advanced SIMD)[1] による SIMD 並列処理を併用して高速化を実現することが期待されている。Android 向け並列ソフトウェアは、NDK(Native Development Kit)[2] を用いて、OpenMP[3] 及び NEON のライブラリ関数を伴う C プログラムとして実装することが可能である。本稿では、OpenMP によるループ並列化と NEON 命令による SIMD 並列化を組み合わせた階層的並列処理手法を提案する。性能評価では、2 次元ウェーブレット変換プログラムに対して提案手法を適用しており、スマートフォン ASUS ZenFone 5Z で行った性能評価の結果、提案手法の有効性が確認された。

2 Android 環境における OpenMP/NEON を用いた並列処理

Android スマートフォンのアプリは、Android Studio の統合開発環境を用いて、Java 言語による開発が広く行われているが、NDK(Native Development Kit) の利用により、Android アプリの一部 (もしくはすべて) を C/C++ で作成することが可能である。C/C++ で作成したコードは、コンパイラにより共有モジュール (.so ファイル) として出力され、Java の実行ファイルから呼び出して利用する。NDK の利用により、OpenMP による並列化や SIMD 命令による並列化が可能になり、Android アプリの高速化が可能になる。

2.1 OpenMP による並列処理

スマートフォンのヘテロジニアスマルチコアを用いて、OpenMP によるループ並列処理を実現するために、指示文 `#pragma omp parallel for` 及びその指示節として、スケジューリング方式を指定することができる。本手法では、4.1 節で述べる 4 種類のスケジューリング方式を伴うループ並列処理を行う。

2.2 SIMD 命令 (NEON) による並列処理

ARM プロセッサでは、NEON[2] と呼ばれる SIMD 命令が用意されている。NEON のデータ型は次のように宣言する。(type)(size)(number of lanes)_t と型が決まっており、例えば、`int16x4_t` は符号付 16bit 整数を 4 個持つ型を意味する。NEON の主な組み込み関数は表 1 の通りである。NEON は 128bit 幅の Q レジスタと 64bit 幅の D レジスタを使用して演算を行う。

3 離散ウェーブレット変換の階層的並列処理

本章では、性能評価に用いる 2 次元ウェーブレット変換とその並列化手法について述べる。

†明治大学総合数理学部ネットワークデザイン学科
Department of Network Design, School of Interdisciplinary
Mathematical Sciences, Meiji University

表 1 NEON の主な組み込み関数。

ロード	vld1q_f32(a)
ストア	vst1q_f32(a)
加算	vaddq_f32(float32x4_t a, float32x4_t b)
乗算	vmulq_f32(float32x4_t a, float32x4_t b)
減算	vsubq_f32(float32x4_t a, float32x4_t b)
除算	vdivq_f32(float32x4_t a, float32x4_t b)




図 1 2 次元ウェーブレット変換の概念。

3.1 Ingrid-Daubechies ウェーブレット変換

Ingrid-Daubechies ウェーブレット変換 [4] は、多重度解像度解析を伴って画像圧縮に用いられるが、本稿では図 1 のようなレベル $j(j=1)$ の計算のみ扱う。スケーリング係数 $s_k^{(j)}$ およびウェーブレット展開係数 $w_k^{(j)}$ は、文献 [4] の数列 p_k と q_k ($N=10$, 数列長=20) を使用し、式 (1) と式 (2) により求める。今回のプログラムでは図 1 のような $n \times n$ の画像 ($n=2048$) を入力とし、ウェーブレット変換によって、 $n \times k(k=1024)$ のスケーリング係数 s 、 $n \times k$ のウェーブレット展開係数 w を求める。同様に s と w に対して垂直方向にウェーブレット変換を適用し、 $s1, w1h, w1v, w1d$ を求める。 $s1$ には $s0$ を平均化した低域成分、 $w1h$ には水平方向の高域成分、 $w1v$ には垂直方向の高域成分、 $w1d$ には対角方向の高域成分が現れる。

$$s_k^{(j)} = \sum_n \overline{p_{n-2k}} s_n^{(j-1)} \quad (1)$$

$$w_k^{(j)} = \sum_n \overline{q_{n-2k}} s_n^{(j-1)} \quad (2)$$

3.2 ウェーブレット変換の並列処理

本節ではレベル $j=1$ の水平方向のウェーブレット変換の過程、即ち図 1(a) の配列 $s0$ を入力として、図 1(b) 左側のスケーリング係数 s を求める過程を説明する。まず、図 1(a) の行単位でマルチコアを用いたループ並列処理を適用する。この並列コードは OpenMP 指示文により実現される。

次に、各行のデータに対して文献 [4] の数列 p_k (数列長=20) との内積を求める際に、NEON の SIMD 命令を用いる。具体的には図 2(a) のような NEON コードを

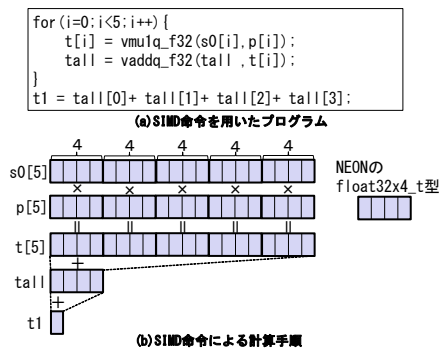


図 2 2次元ウェーブレット変換プログラムにおける SIMD 命令の適応.

表 2 性能評価に用いる Android 搭載マシン.

マシン	ASUS ZenFone 5Z
プロセッサ	Qualcomm Snapdragon 845
CPU コア	Cortex-A75(2.8GHz)+A55(1.8GHz) (4 コア+4 コア)
メモリ	6GB
OS	Android 8.0(API level 26)

実行することにより, スケーリング係数の1つ(この例では変数 t_1) を求めることができる. NEON 命令では 128 ビットのレジスタを用いるため, float 型変数の場合, 4 要素までしか同時に演算することができない. そこで, 20 要素のベクトル内積(図 2(b) の $s_0[5]$ と $p[5]$ の内積)の場合, 4 要素単位の部分ベクトルの内積として求め, それらの総和を $tall$ に求め, 4 要素の和を t_1 に求める. これらの方法により, ループ並列処理と NEON による SIMD 並列化を階層的に行うことが可能になる.

4 Snapdragon845 搭載スマートフォン上での性能評価

本稿では, 2次元ウェーブレット変換プログラム [5] を用いて性能評価を行う. 評価マシンは表 2 のスマートフォンとした. 本性能評価では, 画像圧縮の対象として画像データ (2K:2048*2048) を用意した. 画素値としては Y, Cb, Cr に変換された Y 成分のウェーブレット変換の処理時間を測定した.

4.1 ループ並列処理 (NEON なし) による性能評価

本節では, SIMD 命令 (NEON) を利用せず, ループ並列処理 (4 種類のスケジューリング) のみを 2次元ウェーブレット変換プログラムに適用し評価を行う. 実行結果は図 3 に示す通りであり, ループイタレーションのスケジューリング方法は, (static,1): サイクリック分割, (static): ブロック分割, (dynamic,8): チャンク=8 の動的割り当て, (dynamic,1): チャンク=1 の動的割り当ての 4 種類としている. 評価の結果から, (dynamic,1) の 8 スレッドの場合が最も高速であり, 逐次実行比で 4.97 倍の速度向上率が得られた.

4.2 階層的並列処理 (NEON あり) による性能評価

次に, ループ並列処理 ((dynamic,1) のスケジューリング) と NEON による SIMD 並列化を組み合わせた階層的並列処理による実行結果を図 4 に示す. NEON なし 8 スレッド実行では, 実行時間は 1113[ms] となり逐次実行比で 3.86 倍であった. それに対して, NEON あり 8 スレッド実行では, 実行時間は 215[ms] となり逐次実行比で 19.9 倍となった. これらの結果から OpenMP による並列化と NEON 命令による並列化を組み合わせ

た階層的並列処理手法の有効性が確認できた.

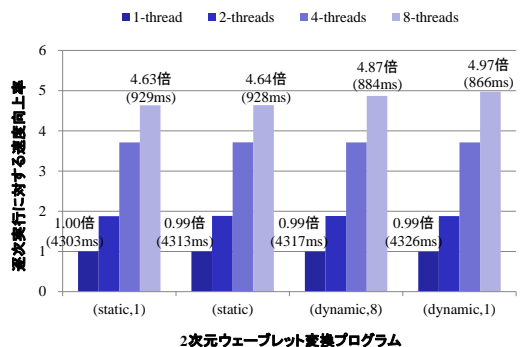


図 3 2次元ウェーブレット変換プログラム上のループ並列処理 (NEON なし) による性能評価.

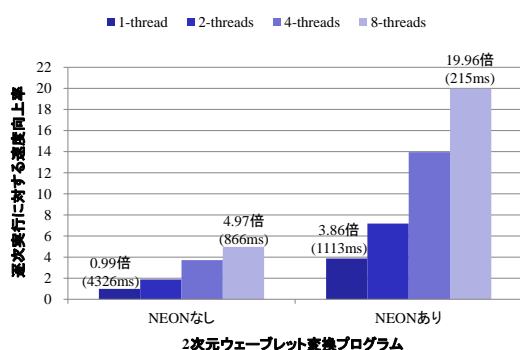


図 4 2次元ウェーブレット変換プログラム上の階層的並列処理 (NEON なし, あり) による性能評価.

5 おわりに

本稿では, OpenMP を用いたループ並列処理と NEON 命令による SIMD 並列化を組み合わせた階層的並列処理手法を提案した. 性能評価では 2次元ウェーブレット変換プログラムに対して提案手法を適用し, Snapdragon845 搭載スマートフォンで性能評価を行った. ループスケジューリング方法は, (dynamic,1) が最も高速であり, さらに SIMD 並列化を組み合わせた階層的並列処理では, 8 スレッド実行で最大 19.96 倍の速度向上が得られた. これらの結果から, NEON 命令を用いた階層的並列処理の有効性が確認された. 今後の課題としては, Android 上でのタスク駆動型粗粒度並列処理 [6] に本手法を組み込むことが挙げられる.

参考文献

- [1] ARM NEON Intrinsics Reference. http://infocenter.arm.com/help/topic/com.arm.doc.ih0073b/IHI0073B_arm_neon_intrinsics_ref.pdf, 2016.
- [2] 出村成和. Android NDK ネイティブプログラミング第 2 版, 秀和システム, 2013.
- [3] OpenMP. <https://www.openmp.org/>, 2018.
- [4] 中野宏毅, 山本鎮男, 吉田靖夫. ウェーブレットによる信号処理と画像処理. 共立出版, 1999.
- [5] 吉川一輝, 高平真由, 吉田明正. マルチ GPU 上での画像圧縮における離散ウェーブレット変換の階層的並列処理, 情報処理学会第 16 回情報科学技術フォーラム I-014, 2018.
- [6] A.Yoshida, A.Kamiyama, H.Oka. A Task-Driven Parallel Code Generation Scheme for Coarse Grain Parallelization on Android Platform. Journal of Information Processing, Vol.25, pp.426-437, 2017.