インテル・テクノロジー講座
ソフトウェア最適化方法論（2）

インテル株式会社

2017 年度HAL版

コースの内容

- SIMD 命令とベクトル化
- 並列化とOpenMP
- 最新プロセッサでのデモ
  - 最内ループをベクトル化して最外ループを並列化

ベクトル化

ベクトル化とはインテル® マイクロプロセッサーがサポートする、SIMD命令（SSEやAVX命令等）を利用して、1 つの命令で複数のデータを処理するようなコードを生成する最適化技術であり、多くの場合ループ内のデータ演算や操作に適用できる

```
for (i = 0; i < MAX; i++)
    c[i] = a[i] + b[i];
```

ベクトル化は数値演算固有のものではない

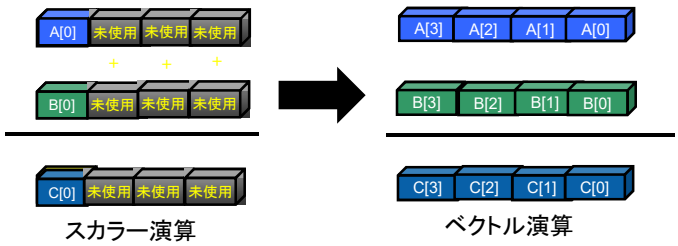

より多くのコア、広いベクトル、コプロセッサー

パフォーマンスを得るには、ツールは 並列性を考慮しなければならない

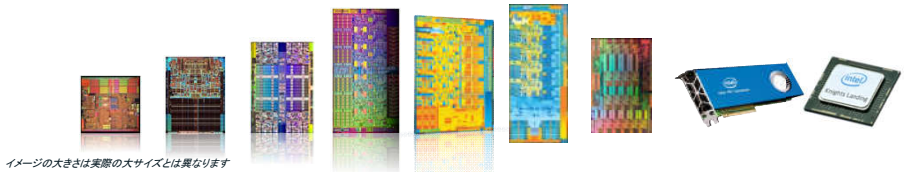

イメージの大きさは実際の大サイズとは異なります

	インテル® Xeon® プロセッサー 64 ビット	インテル® Xeon® プロセッサー 5100 シリーズ	インテル® Xeon® プロセッサー 5500 シリーズ	インテル® Xeon® プロセッサー 5600 シリーズ	Intel® Xeon® プロセッサ E5-2600 (Sandy Bridge)	Intel® Xeon® プロセッサ E5-2600 v2 (Ivy Bridge)	Intel® Xeon® プロセッサ E5-2600 v3 (Haswell)	Intel® Xeon Phi™ コプロセッサ 7100A	Knights Landing
コア数	1	2	4	6	8	12	14	61	>61
スレッド数	2	2	8	12	16	24	28	244	>240
SIMD 幅	128	128	128	128	256	256	256	512	512
	SSE2	SSSE3	SSE4.2	SSE4.2	AVX	AVX	AVX2 FMA	IMCI	AVX512

ソフトウェアの挑戦： スケーラブルなソフトウェアを開発する

ベクトル命令の概要

ベクトル命令のフォーマット（ここではMASMの形式で表記する）

- 明示的に結果を送るレジスタを指定する 3 オペランド形式

  instruction destination, source1, source2

  → 入力レジスタの内容は破壊されない

  → コードをコンパクトにできる

- (大概の) MIC 命令はマスクすることができる

  *instruction destination **{mask}**, source1, source2*

  → マスクされた部分は非破壊的である、つまり、結果を送る先の値は保持される

- 例:

vaddps zmm1{k1},zmm2,zmm3

Fused Multiply Add（乗加算）

Multiply-Add (デスティネーションは最初のソース)

- Vfmadd231ps v0, v5, v6 ; v0=v5*v6+v0
- オペランド 2 にオペランド 3 を掛けて、オペランド 1 に加算

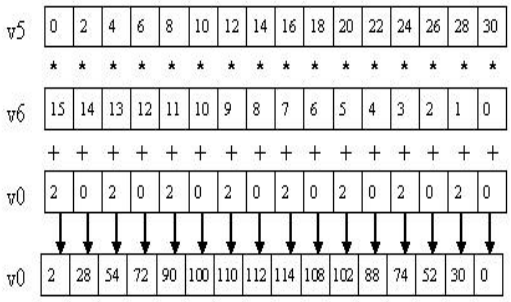

SIMD 命令によるベクトル化

ソフトウェアがプロセッサーのリソースを
効果的に使用しているかどうかを判断する

1. コンパイラーのレポートを解析し、最適化を妨げる要因を見つける
2. 適切なオプション、プラグマ、およびループ変換を利用する

一般的なループのベクトル化の問題

- 非依存性
  - ループの反復は依存性があってはならない
- ループに関する制限:
  - ループ内の変数は明確でなければならない
  - 一部の依存ループはベクトル化が可能
  - 多くの関数呼び出しはベクトル化できない
  - 一部の条件分岐はベクトル化を妨げる
  - ループはカウント可能でなければならない
  - ネストするループの外部ループはベクトル化できない
  - 混在データ型はベクトル化できない
  - その他

定義

- ループの非依存性(independency)とは:
  ループの反復 i は反復 i+1(i-1) に依存しない

```
int a[MAX], b[MAX];
for (i = 0; i < MAX; i++) {
        a[i] =  b[i] ;
}
```

コンパイラーによるベクトル化や並列化に影響

重要度

OpenMP*: 並列処理
自動並列化: 並列処理
インテル® Cilk™ Plus: 並列処理

} 影響大

SIMD: ベクトル化
（MMX、SSE、SSE2、SSE3、SSE4、AVX）
SWP: ソフトウェアのパイプライン化

OOO: アウトオブオーダー・コア

ILP: 命令レベルの並列処理

O3: ループ変換による最適化

} 影響あり

依存性とは何か

- 依存性は手続き型(インパラティブ)言語の不可欠な要素
- 実行順序に結果が依存する！！
- 実行文間の関係
- ループに適用できる

```
A=0;
A=A+2;
B=A;
```

```
A=0;
B=A;
A=A+2;
```


フロー依存

- 書き込み後の読み取り(RAW)
- ループ間のフロー依存:
- 変数を書き込んでから
  別のループで読み取る

```
for (j=1; j<MAX; j++) {
        A[j]=A[j-1];
}

        A[1]=A[0];

        A[2]=A[1];
```

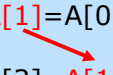

sample1.c

書き込みが完了しないと、依存性のある読み込みは開始できない

逆依存

- 読み取り後の書き込み（WAR）
- ループ間の逆依存：
- 変数を読み取ってから別のループで書き込む

```
for (j=1; j<MAX; j++) {
        A[j]=A[j+1];
}

        A[1]=A[2];
        A[2]=A[3];
```

sample2.c

読み込みが完了しないと、依存性のある次の書き込みは開始できない

出力依存

- 書き込み後の書き込み（WAW）
- ループ間の出力依存：
- 変数を書き込んでから別のループで同じ場所に再度書き込む

```
for (j=1; j<MAX; j++) {
        A[j]=B[j];
        A[j+1]=C[j];
}

        A[1]=B[1];
        A[2]=C[1];
        A[2]=B[2];
        A[3]=C[2];
```

sample3.c

書き込みが完了しないと、依存性のある次の書き込みは開始できない

単純なテスト

ループの順序を反転して再実行する

結果が同じ場合、ループは独立している§

```
for(j=0;j<MAX;j++){
     <...>
   compute(j,...)
     <...>
}
```

反転

```
for(j=MAX-1;j>=0;j--){
     <...>
   compute(j,...)
     <...>
}
```

sample4.c

§ 例外: 帰納変数を含むループ

依存関係の排除

依存関係の排除は他の最適化を改善するため、最良の選択

並列処理では必須

すべての依存関係を排除できるわけではない

```
for (j=1; j<MAX; j++) {
        A[j]=A[j-1] + 1;
}
```

```
for (j=1; j<MAX; j++) {
        A[j]= A[0] + j;
}
```

sample5.c

リダクション

リダクションは、結合演算により配列データをスカラーデータに変換する

リダクションを利用して、プライベート領域の部分和を計算する

次に、アクセスが同期するように注意しながら、部分的な結果を共有結果と組み合わせる

```
for (j=0; j<MAX; j++)
  sum = sum + c[j];
```

sample11.c

リダクション変数はループ内でフロー依存が発生する
ループを並列化するには排除しなければならない問題

データのあいまいさとコンパイラー

- ループの反復は非依存か?
- 通常コンパイラーはこれを判別できない
- 最適化の余地はない
  エラーなしで実行するために、コンパイラーは a と b のオーバーラップを仮定する

```
void func(int *a, int *b) {
  for (j=0;j<MAX;j++) {
        a[j] = b[j];
  }
}
```

関数呼び出し

- 一般的に関数呼び出しは ILP 妨げる

呼び出される関数のデータスコープ内の依存性を見つけることが困難

```
for (j=0;j<MAX;j++) {
        compute(&a[j],&b[j]);
        a[j]=sin(b[j]);
}
```

- 例外:
  - 超越関数
  - IPO 最適化コンパイル

sample12.c

SVML ライブラリーを使用した数学関数

SVML（Short vector math library）により効率的なソフトウェア実装を提供:

- sin/cos/tan
- asin/acos/atan
- sinh/cosh/tanh
- asinh/acosh/atanh
- log10/ln
- exp/pow
- ... その他

状態依存の関数呼び出し

多くのルーチンは呼び出しの状態を維持する
- メモリー割り当て
- 擬似乱数生成
- I/O ルーチン
- グラフィック・ライブラリー
- サードパーティー・ライブラリー

これらのルーチンの並列アクセスは同期されていない限り安全ではない

スレッドの安全性を確実にするため特定の関数におけるリソースのアクセスを確認する

以下のループの依存性を識別する

```
for (i=0;i<MAX-2,i++) {
A[i+2]=A[i] + 1;
}
```

```
for (i=0;i<MAX-1,i+=2) {
A[i+1]=A[i] + 1;
}
```

```
for (i=1;i<MAX,i++) {
A[i]=A[i-1] * 2;
B = A[i-1];
}
```

```
for (i=0;i<MAX,i++) {
A[j][i+1] = A[k][i] + B
}
```


以下のループの依存性を識別する

```
for (i=0;i<MAX-2,i++) {
A[i+2]=A[i] + 1;
}
```

A[2] = A[0] + 1
A[3] = A[1] + 1
A[4] = A[2] + 1

```
for (i=0;i<MAX-1,i+=2) {
A[i+1]=A[i] + 1;
}
```

A[1] = A[0] + 1
A[3] = A[2] + 1
A[5] = A[4] + 1
奇数　偶数

以下のループの依存性を識別する

```
for (i=1;i<MAX,i++) {
A[i]=A[i-1] * 2;
B = A[i-1];
}
```

A[1] = A[0] * 2
B = A[0]

A[2] = A[1] * 2
B = A[1]

```
for (i=0;i<MAX,i++) {
A[j][i+1] = A[k][i] + B
}
```

A[j][1] = A[k][0] + 1

A[j][3] = A[k][2] + 1

A[j][5] = A[k][4] + 1

ベクトル化可能なループとは

1. 単純な「if 文」構造ブロックを含むループ
2. 一部の組み込み関数（SVML） を含むループ
3. スカラー演算（リダクション）を行うループ
4. 非ユニットのストライド（非効率的）を行うループ

ループをベクトル化できる可能性は多い

ループがベクトル化されなかった理由:
"ループ回数が少なすぎる"

ループで SSE 命令を使用すると、オーバーヘッドが発生する
反復回数が少ないループをベクトル化すべきではない
コンパイラーにループの大きさを知らせる

```
for (i = 0; i < MAX1; ++i) {
      a1[i] = b1[i] * c1[i] + d1[i];
  }

for (i = 0; i < n; ++i) {
     a2[i] = b2[i] * c2[i] + d2[i];
  }
```

ループがベクトル化されなかった理由:
"ループ回数が少なすぎる"

ループで SSE 命令を使用すると、オーバーヘッドが発生する
反復回数が少ないループをベクトル化すべきではない
コンパイラーにループの大きさを知らせる

```
#pragma loop count(5)
   for (i = 0; i < MAX1; ++i) {
       a1[i] = b1[i] * c1[i] + d1[i];
   }

#pragma loop count(1000)
   for (i = 0; i < MAX2; ++i) {
      a2[i] = b2[i] * c2[i] + d2[i];
   }
```


ループがベクトル化されなかった理由:
"ベクトル化しても非効率"

ループが大きいと、非常に多くのレジスターが必要になる

```
for (i = 0; i < N; i++) {
  A[i] = B[i] * max(C[i], D[i]) + F[i] - E[i];
  G[i] = H[i] * sin(I[i]) + J[i] / K[i];
}
```

sample15.c

他の問題によってもこの警告が出力されることがある

ループがベクトル化されなかった理由:
"ベクトル化しても非効率"

ループが大きいと、非常に多くのレジスターが必要になる

- ソリューション: ループの分割
  - **#pragma distribute point – ループの分割を指示**

```
for (i = 0; i < N; i++) {
  A[i] = B[i] * max(C[i], D[i]) + F[i] - E[i];
  #pragma distribute point
  G[i] = H[i] * sin(I[i]) + J[i] / K[i];
}
```

sample15.c

  - 2 つのループに分割可能であるヒントをコンパイラーへ指示

他の問題によってもこの警告が出力されることがある

ループがベクトル化されなかった理由:
"サポートされないループ構造"

```
struct _xx { int data; int bound; };

doit1(int *a, struct _xx *x) {
for (int i = 0; i < x->bound; i++)
            a[i] = 0;
}
```

サポートされないループ構造とは、カウントできないループ、またはコンパイラーがループ回数をランタイム時に判定できないループを意味する

ループがベクトル化されなかった理由:
"ベクトルの依存関係が存在する"

ループの反復に依存関係がないか?

または

コンパイラーが 2 つのポインターがエイリアスではないと仮定できない（メモリー内でオーバーラップする可能性あり）

```
void scale(float *z, float *x) {
        for (i = 0; i < 100; i++)
                z[i] = A * x[i];
}
```

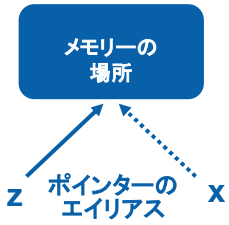

ベクトルレポート問題に対するソリューション

後に続くループのベクトル化を制御する

- **#pragma novector** – ループのベクトル化が有効な場合でもループをベクトル化しない
- **#pragma vector always** – メリットと例外検出に関するヒューリスティックを無視して常にループをベクトル化する

```
#pragma vector always
  for (i = 0; i < MAX; ++i) {
      a[i] = b[i] * c[i] + d[i];
  }
```

推奨する明確化スイッチ

Linux*	Windows*
-ipo	/Qipo

IPO によるグローバルなスタティック解析は
ポインターを明確化できる

-restrict	/Qrestrict

restrict オプションはポインターの明確化を有効にする

明確化: "restrict" キーワード

ISO C99 規格の一部

次のコマンドライン・スイッチが必要:

Linux*	Windows*
-restrict	/Qrestrict
-c99	/Qstd=c99

```
void foo(int *x, int *y, int * restrict z) {
   int i;
   for (i = 0; i < 100; i++)
        z[i] = A * x[i] + y[i];
}

 // 2 次元配列の例
 void mult(int a[][NUM], int b[restrict][NUM]);
```

sample18.c

明確化: プラグマ

ベクトルの依存関係をコンパイラーに無視させる

```
#pragma ivdep
   for (i = 0; i < 100; i++)
          z[i] = A * x[i] + y[i];

#pragma simd
   for (i = 0; i < 100; i++)
          z[i] = A * x[i] + y[i];
```


明確化のテスト

Linux*	Windows*
-fno-alias	/Oa

ソースファイルのすべてのポインターはエイリアスされないと仮定する

-fno-fnalias	/Ow
-alias_args[-]	/Qalias_args[-]

関数内にエイリアスが存在しないと仮定する
（つまり、ポインター引数は一意）

-ansi_alias[-]デフォルト/Qansi_alias[-]

異なるタイプのポインター間のエイリアスが存在しないと仮定する

ベクトル化レポート

```
Intel(R) C++ Intel(R) 64 Compiler XE for applications running on Intel(R)
64, Version 12.0.0.104 Build 20101006
Copyright (C) 1985-2010 Intel Corporation.  All rights reserved.

novec.cpp(59) (col. 19): remark: LOOP WAS VECTORIZED.
```

デフォルトではベクトル化されたかどうかは通知されない

/Qvec-report（-vec-report ）は、
コンパイラーがベクトル化できた/できなかった場所を通知する

ベクトル化レポートのオプション

ベクトル化に関するレポートを表示
/Qvec-report[:n] （-vec-report=n）

ベクトライザーの診断レベルを設定する

n=*0*: 診断情報を表示しない
n=1: ベクトル化されたループのみを表示する（デフォルト）
n=*2*: ベクトル化されなかったループとその理由も表示する
n=3: 依存情報も表示する
n=4: ベクトル化されなかったループのみを表示する
n=5: ベクトル化されなかったループのみを表示し、依存情報も表示する

ベクトル化レポート

```
Intel(R) C++ Intel(R) 64 Compiler XE for applications running on Intel(R) 64, Version
12.0.0.104 Build 20101006
Copyright (C) 1985-2010 Intel Corporation.  All rights reserved.

novec.cpp(40) (col. 3): remark: loop was not vectorized: not inner loop.
novec.cpp(41) (col. 5): remark: loop was not vectorized: not inner loop.
novec.cpp(43) (col. 7): remark: loop was not vectorized: existence of vector
dependence.
novec.cpp(50) (col. 3): remark: loop was not vectorized: existence of vector
dependence.
novec.cpp(67) (col. 4): remark: loop was not vectorized: vectorization possible but
seems inefficient.
```

/Qvec-report4はベクトル化できなかった場所を通知する

ガイドレポート

バージョン 12 のインテルコンパイラーでは、新たにガイド付き最適化（/Qguide オプション）がサポートされています。この機能とレポート機能の違いは、レポートでは問題点は報告してくれますが、問題は開発者自身が考えて直さなければならない。ガイドによる最適化では、どのように問題に対処すべきか、コンパイラーがアシストメッセージを出力してくれる

```
// サンプルコード: sample20.c
#include "mul.h"
void matvec(float a[][COLWIDTH], float b[], float x[]){
int i, j, sz1 = size1; sz2 = size2;
        for (i = 0; i < sz1; i++) {              // 5 行目
        b[i] = 0;
                for (j = 0;j < sz2; j++) {       // 7 行目
                b[i] += a[i][j] * x[j];          // 8 行目
                }
        }
}
```

icl sample20.c /Qguide (icc sample20.c –guide)

ガイドレポート

remark #30761: コンパイラーに自動並列化を向上させるアドバイスを生成させる場合は -Qparallel オプションを追加します。

\sample20.c(9): remark #30536: (LOOP) 必要に応じて、-Qno-alias-args オプションを追加してコンパイラーによる型ベースの一義化解析を向上できます (オプションはコンパイル全体に適用されます)。これにより、行 9 のループがベクトル化され最適化が向上します。

[確認] コンパイル全体でこのオプションのセマンティクスに沿っていることを確認してください。[別の方法] ルーチン "matvec" のすべてのポインター型の引数に "restrict" キーワードを追加することで同様の効果が得られます。これにより、行 9 のループがベクトル化され最適化が向上します。

[確認] "restrict" ポインター修飾子のセマンティクスに沿っていることを確認してください。ルーチンにおいて、そのポインターによってアクセスされるすべてのデータは、ほかのポインターからはアクセスできません。

このコンパイルセッションで出力されたアドバイス・メッセージの数: 1。

コースの内容

- SIMD 命令とベクトル化
- 並列化とOpenMP
- 最新プロセッサでのデモ

なぜ並列処理を使用するのか?

- 計算をより短い時間で処理

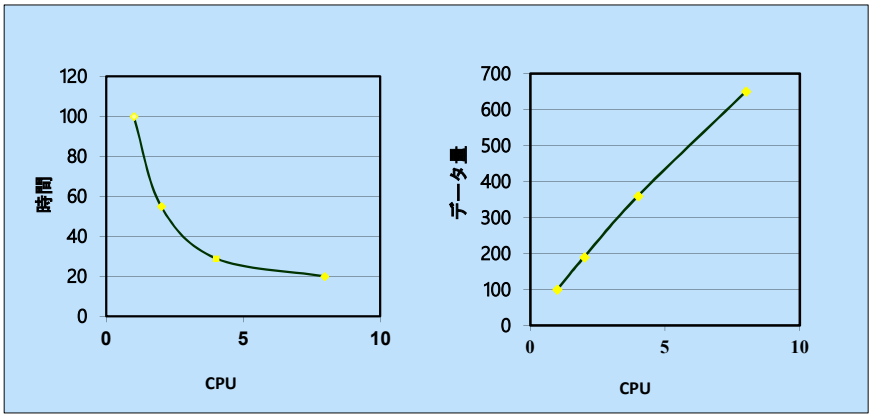

スレッドとプロセス

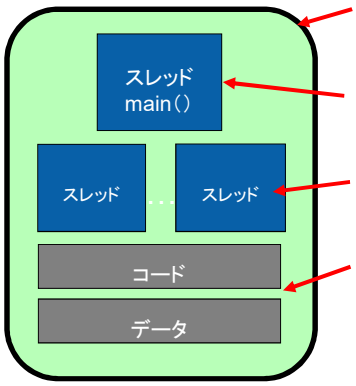

- 現在のオペレーティング・システムではプログラムをプロセスとしてロードする
- プロセスはエントリーポイントでスレッドとして実行を開始する
- スレッドはプロセス内で他のスレッドを作成できる
- プロセス内のすべてのスレッドはコードとデータ領域を共有する
- スレッドは 2 つのスケジュール状態(アクティブ、インアクティブ)を持つ

コンカレンシー（並行性）とパラレリズム（並列性）

- 並行性：2 つもしくはそれ以上のスレッドが同時に進行する

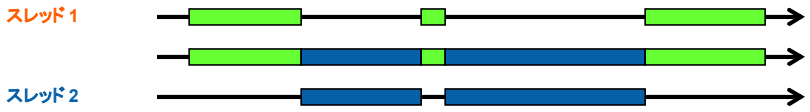

- 並列性：2 つもしくはそれ以上のスレッドが同時に実行される

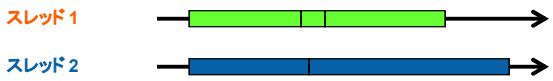

なぜスレッドを利用するのか？

- 利点
  - パフォーマンスの向上
  - リソースの利用率を改善
- 欠点
  - アプリケーションがより複雑になる
  - デバッグが困難（データ競合、デッドロック、その他）

主要な 5 つの並列化手法

- いずれの手法を導入するか？
  - メッセージ・パッシング
    - MPI、PVM
  - 明示的なスレディング
    - Windows スレッド API、Pthreads、Solaris スレッド、Java スレッド・クラス
  - コンパイラーのサポート
    - 自動並列化、OpenMP、インテル・スレッディング・ビルディング・ブロック(TBB)
  - 並列プログラミング言語
    - HPF、CAF、UPC、CxC、Cilk Plus
  - 並列マス・ライブラリー
    - ScaLAPACK、PARDISO、PLAPACK、PETsc

Hello World

```
DWORD WINAPI HelloFunc (LPVOID)
{
        cout << "Hello Thread\n";
        return 0;
}

HANDLE hThread[numThreads];

for (int i = 0; i < numThreads; i
      hThread[i] = CreateThread

// Clean up thread handles
for (int i = 0; i < numThreads; i++)
        CloseHandle (hThread[i]);

return 0;
```

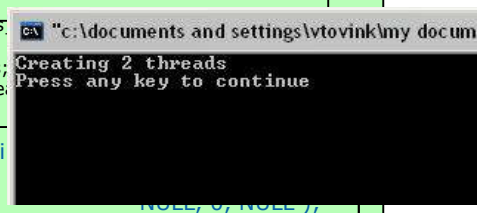

Hello World（変更後）

```
for (int i = 0; i < numThreads; i++)
      hThread[i] = CreateThread (NULL, 0, HelloFunc,

getchar();

// Clean up thread handles
for (int i = 0; i < numThreads; i++)
        CloseHandle (hThread[i]);

return 0;
```

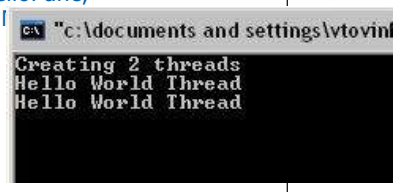

サンプル・コードの変更

“Hello World Thread <スレッド番号>” メッセージに変更するには？

Hello World Thread #1
Hello World Thread #0

アムダールの法則

- 並列化のスピードアップ（スケーリング）の上限を説明
- オーバーヘッドの影響を考慮する際に役立つ

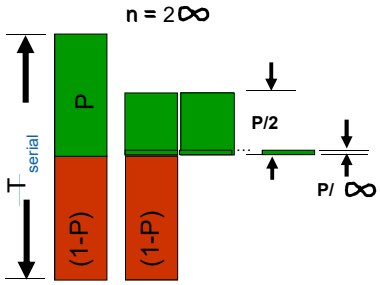

0.5 + 0.025

Tparallel = {(1-P) + P/n + O} Tserial

n = プロセッサーの数

スケーリング = Tserial / Tparallel 1100075 = 2.03

シリアルコードがスケーリングを制限する

並列プログラミング・モデル

- 機能分割
  - タスクの並列処理
  - 同じ問題の独立したタスク
    - UI タスク、UI 更新、生産と消費のパラダイム
    - 並列演算と次の表示タスク
- データ分割
  - 異なるデータで実行される同じ演算
  - 例: 行列の乗算

アプリケーションをスレッド化する際によくある質問

- どこをスレッド化すればいいのか?
- スレッド化に必要な時間は?
- 必要な再設計の回数は?
- 選択した領域をスレッド化する価値はあるか?
- どの程度のスピードアップを期待すべきか?
- パフォーマンスは期待値を満たすことができるか?
- プロセッサーを追加すれば性能が向上するか?
- どのスレッドモデルを使用すべきか?

素数をカウントするサンプルコード

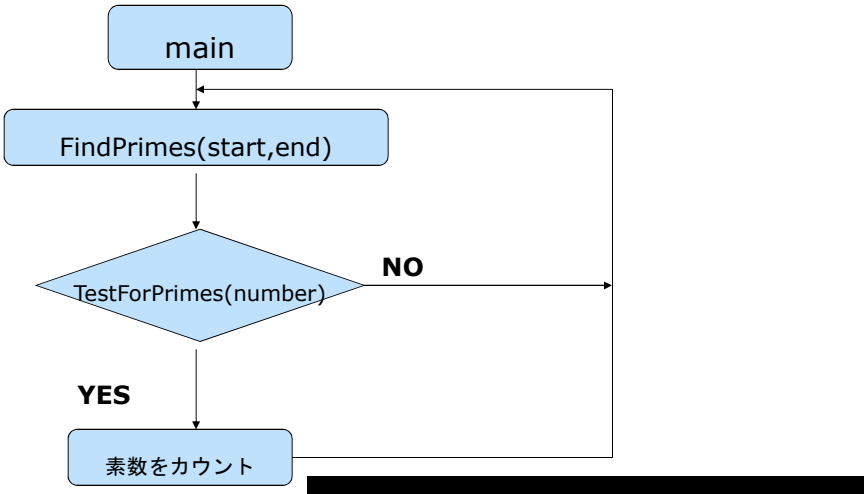

ケーススタディー

素数をカウントするサンプルコード

```
8 primes found between      1 and     20 in    0.00 secs
```

```
2
3  3
5     5
7        7
9
11             11
13
15
17
```

```
    limit = (long)(sqrtf((float)val)+0.5f);
    while( (factor <= limit) &&
           (val % factor))
            factor ++;

    return (factor > limit);
}

for( int i = start; i <= end; i+= 2 ){
    if( TestForPrime(i) )
        gPrimesFound++;
}
}
```


OpenMP* プログラミングをはじめる
どこをスレッド化すればいいのか?

- シングルスレッド "Pr
VTune™ Amplifier X

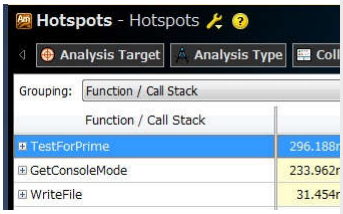


```
bool TestForPrime(int val)
{   // let's start checking from 3
    int limit, factor = 3;
    limit = (long)(sqrtf((float)val)+0.5f);
    while( (factor <= limit) &&
           (val % factor))
            factor ++;

    return (factor > limit);
}

void FindPrimes(int start, int end)
{
    // start is always odd
    int range = end - start + 1;
    for( int i = start; i <= end; i+= 2 ){
        if( TestForPrime(i) )
            gPrimesFound++;
    }
}
```

時間のかかる領域を特定する

OpenMP* プログラミングをはじめる
どこをスレッド化すればいいのか?

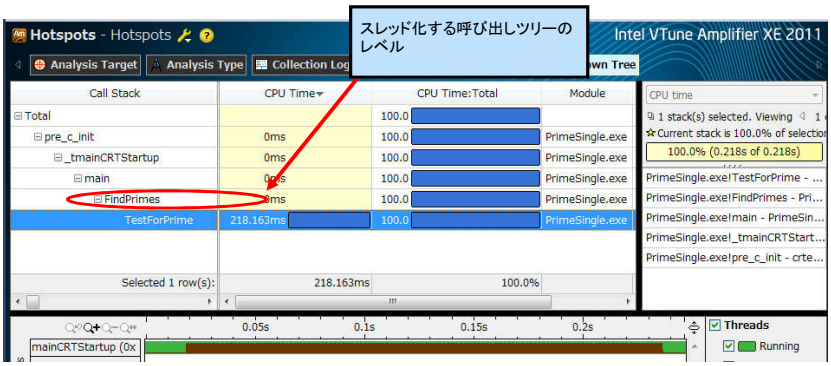

スレッド化する呼び出しツリーのレベルを特定する

OpenMP* プログラミングをはじめる
選択した領域をスレッド化する価値はあるか?

コードのどの位置で並列化を実装するか、インテル® Parallel Advisor を使って性能を見積もる

```
ANNOTATE_SITE_BEGIN(prime);
    for( int i = start; i <= end; i+=2 ){
ANNOTATE_TASK_BEGIN(openmp);
        if( TestForPrime(i) )
            gPrimesFound++;
ANNOTATE_TASK_END(openmp);
    }
ANNOTATE_SITE_END(prime);
```

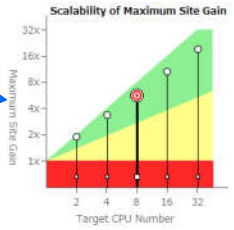

スピードアップする場所が見つかったら、
OpenMP で並列化を実装する

OpenMP* プログラミングをはじめる
データの整合性をチェックする

プログラム・コード中の競合の可能性のある変数を見つける

インテル® コンパイラーの診断機能を利用すると;

>icl PrimeSingle.cpp /Qdiag-enable:thread

スタティック変数の利用、代入、参照をチェックできる

```
Primesingle.cpp
Primesingle.cpp(15): 警告 #1711: 静的に割り当てられた変数 "gProgress" への代入
    gProgress++;
    ^
Primesingle.cpp(16): 警告 #1710: 静的に割り当てられた変数 "gProgress" への参照
    percentDone = (int)((float)gProgress/(float)range *200.0f + 0.5f);
                   ^
Primesingle.cpp(39): 警告 #1711: 静的に割り当てられた変数 "gPrimesFound" への代入
                    gPrimesFound++;
                    ^
Primesingle.cpp(49): 警告 #1711: 静的に割り当てられた変数 "gPrimesFound" への代入
    gPrimesFound = 1;  // 2 は特殊ケースなので1つカウント
    ^
Primesingle.cpp(56): 警告 #1710: 静的に割り当てられた変数 "gPrimesFound" への参照
        start, end, gPrimesFound,(float)(after - before)/ CLOCKS_PER_SEC);
                    ^
```


OpenMP* プログラミングをはじめる
データの整合性をチェックする

インテル® Parallel Advisor を使って性能を見積もるとともに、データの整合性をチェックできる

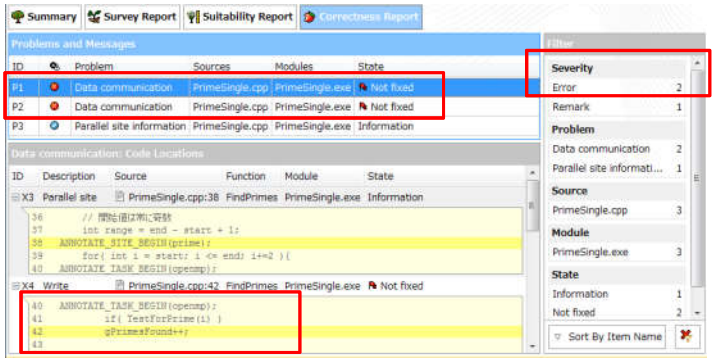

OpenMP* プログラミングをはじめる

どこをスレッド化すればいいのか?

- どこをスレッド化すればいいのか?
  - FindPrimes()
- 選択した領域をスレッド化する価値はあるか?
  - 依存関係が少ない
  - データを並列化できる
  - 実行時間の多く（ 90% 以上）を占める

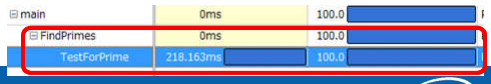

OpenMP* プログラミングをはじめる

選択した領域をスレッド化する価値はあるか? どの程度のスピードアップが期待できるか?

- 予想されるメリットは? 並列化対象のコードが全体の 100% を占める場合

スケーリング（8P） = 100/(100/8) = ~8 x
（8 コアシステムでの実行を想定）

- 最小限の作業で予想されるメリットを判断する方法は?

OpenMP* を使用した素早いプロトタイプ作成

- スレッド化に必要な時間は?
- 必要な再設計の回数は?

OpenMP* プログラミングをはじめる

どのようにスレッドに負荷を分散するか?

```
#pragma omp parallel for
    for( int i = start; i <= end; i+= 2 ){
        if ( TestForPrime(i) )
            gPrimesFound++;
        ShowP
    }
```

OpenMP*

for ループでワークシェアを定義する

この並列領域のスレッドをここで作成する

OpenMP* プログラミングをはじめる

どの程度のスピードアップが期待できるか?

- 予想されるメリットは?
- 最小限の作業で予想されるメリットを判断する方法は?

6.36 / 1.9 = 3.34 x のスケーリング

- スレッド化に必要な時間は?
- 必要な再設計の回数は?
- 可能な最良のスケーリングか?

OpenMP* プログラミングをはじめる
正当性のデバッグ

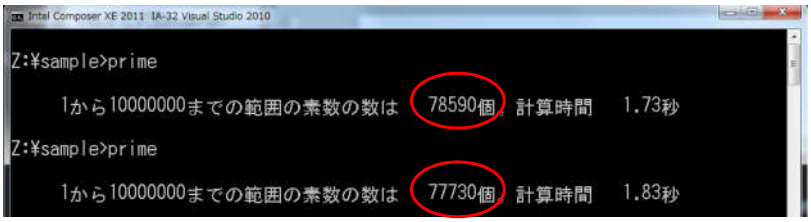

- 毎回答えが同じであるか?
  このスレッドの実装は正しいか?

OpenMP* プログラミングをはじめる
正当性のデバッグ

- インテル® Inspector XE は、データの競合、ストール、およびデッドロックなどのスレッド化の問題を正確に検出する

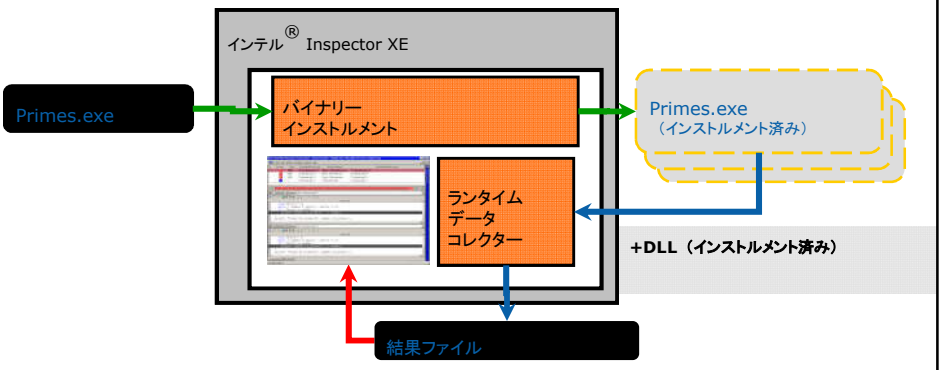

インテル® Inspector XE で問題を検出

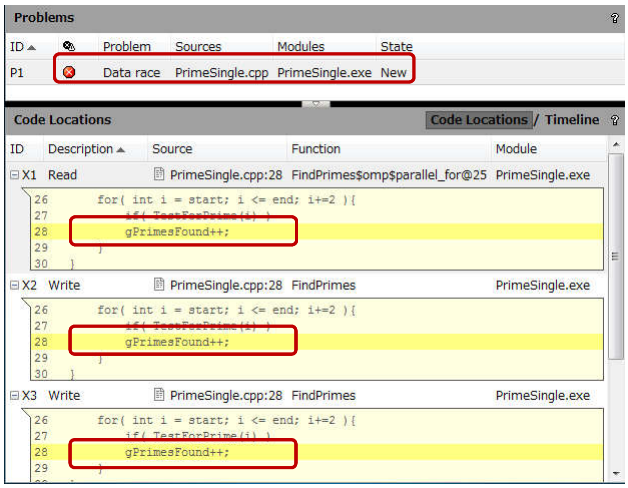

8 スレッド動作中

OpenMP* プログラミングをはじめる
正当性のデバッグ

```
#pragma omp parallel for
    for( int i = start; i <= end; i+= 2 ){
      if( TestForPrime(i) )
#pragma omp atomic
          gPrimesFound++;
    }
```

アトミック演算で
インクリメントする

この同期は最適か？

```
#pragma omp parallel for reduction(+:gPrimesFound)
    for( int i = start; i <= end; i+= 2 ){
      if( TestForPrime(i) )
        gPrimesFound++;
    }
```

OpenMP* プログラミングをはじめる
パフォーマンス

- 6.36 / 1.78 = 3.57 x のパフォーマンスは最適か?
- このアルゴリズムから期待できる最良のパフォーマンスか?

OpenMP* プログラミングをはじめる
パフォーマンスの検証

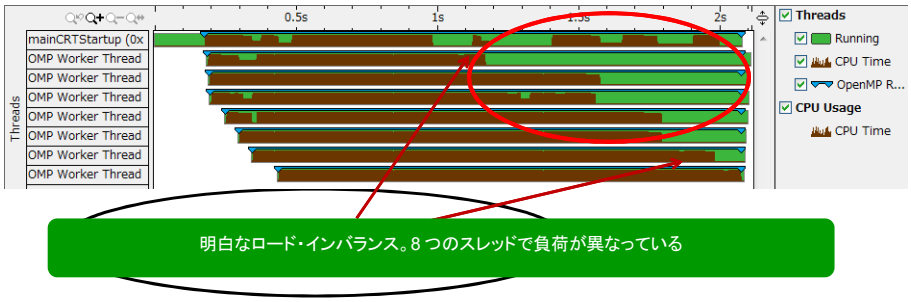

設計段階に戻る

OpenMP* プログラミングをはじめる
パフォーマンスの検証

- OpenMP における for ワークシェア構文のデフォルトのスケジュールは?
- ループのブロック分割

```
#pragma omp parallel for reduction(+: gPrimesFound)
    for( int i = start; i <= end; i+= 2 ){
      if( TestForPrime(i) )
          gPrimesFound++;
    }
```

TestForPrimeは値が大きいほど判定に時間がかかる

このループは、i = 1 から 10000000 までを、8 つのブロックに分割される

つまり最後のブロックを処理するスレッドに負荷が大きくかかる

OpenMP* プログラミングをはじめる
パフォーマンスの改善

```
#pragma omp parallel for reduction(+: gPrimesFound) schedule(auto)
    for( int i = start; i <= end; i+= 2 ){
      if( TestForPrime(i) )
          gPrimesFound++;
    }
```

for ワークシェア構文に schdule(auto) 節を追加してスケジュールを変更

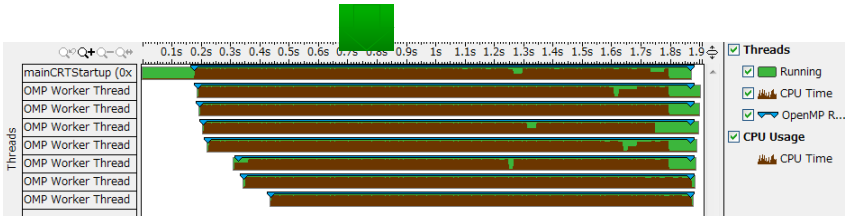

OpenMP* プログラミングをはじめる
パフォーマンスの再確認

6.36 / 1.59 = 4.0 x のパフォーマンスは最適か?

このアルゴリズムはプロセッサーコアが増加すると
適切にスケールする

質問の再確認

アプリケーションをスレッド化する際によくある質問
- どこをスレッド化すればいいのか?
- 選択した領域をスレッド化する価値はあるか?
- どの程度のスピードアップが期待できるか?
- どのようにスレッドに負荷を分散するか?
- プロセッサーを追加すれば性能が向上するか?
- どこでスレッド化と最適化を終了できるか?

セクションによる簡単な並列化

```
main()
{
#pragma omp parallel sections
{
 /* task 1 */
#pragma omp section
 {
  printf("I am sleeping 1\n");
  sleep(5);
 }

 /* task 2 */
#pragma omp section
 {
  printf("I am sleeping 2\n");
  sleep(5);
 }
}
}
```


コースの内容

- SIMD 命令とベクトル化
- 並列化とOpenMP
- 最新プロセッサでのデモ
  - 際内ループをベクトル化して最外ループを並列化

まとめ

- SIMD命令を利用したベクトル化の為には依存性等のベクトル化を妨げる要因を見つけて排除する
- 最新のプロセッサではOpenMP等の並列化を行ってすべてのコアを有効利用
- 最内側ループをベクトル化し、最外側ループを並列化することにより最大限の性能を実現